

Tadeusz Cisowski

# Rola i miejsce szkolenia w zarządzaniu potokami transportowymi na kolei

*Procesy decyzyjne tylko w prostych systemach rzeczywistych można opisywać i efektywnie analizować za pomocą modeli analitycznych. W przypadku systemów wielkich i złożonych, przydatnymi mogą okazać się modele i metody wspomaganie decyzji, oparte na inteligentnych technologiach informatycznych, zapewniające rozwiązanie zadań słabo sformalizowanych, o niepełnych, niedokładnych i dynamicznie zmieniających się danych. Modele takie stają się szczególnie efektywne przy podejściach heurystycznych i konceptualnej obróbce informacji.*

W dostępnej literaturze znane są oferty metodologiczne, bazujące na intelektualizacji technologii informatycznych, dotyczące systemów eksperckich, pozwalające na modelowanie symulacyjne procesów podejmowania decyzji przez ekspertów. W trakcie modelowania zachodzi wnioskowanie logiczne w warunkach niepełnej informacji i uzyskuje się rozwiązania (rekomendacje) na podstawie analizy drzewa rozwiązań.

Obserwuje się przy tym aktywne przejście od teoretycznych badań systemów eksperckich do ich praktycznego wdrożenia. Świadczy to o możliwości zapewnienia przez te systemy wysokiej efektywności procesów zarządzania, poprzez generowanie zarówno gotowych wariantów rozwiązań optymalnych, jaki i wspomaganie logiczne i informatyczne procesu podejmowania decyzji.

Jednym z ważniejszych zadań budowy symulacyjnych modeli zarządzania procesem przewozowym jest budowa algorytmu klasyfikacji sytuacji lub algorytmu reguł decyzyjnych. Algorytm taki można zbudować na podstawie adaptacji i szkolenia, które prowadzi nauczyciel pomagający w procesie zarządzania sformułować algorytm zachowania się systemu w sytuacjach wyboru decyzji po zakończeniu szkolenia. W praktyce nauczycielem tym jest decydent, którego rozwiązania podjęte w konkretnych sytuacjach wyboru są podstawą szkolenia symulacyjnego modelu zarządzania. Oczywiście jest, że decydent w praktyce może podejmować decyzje nie do końca trafne i decyzje te wykorzystywane są dalej w procesie szkolenia. Z czasem „zakorzeniają” się one w systemie zarządzania i prowadzą do niepożądanych następstw w przyszłych sytuacjach wyboru rozwiązań.

W związku z „nieidealnością” realnego nauczyciela powstają dwa zadania [3]. Pierwsze z nich polega na badaniu wpływu „nieidealnego” nauczyciela na proces szkolenia systemu zarządzania. Zadanie drugie sprowadza się do korekty algorytmów decyzji, podjętych przez „nieidealnego” nauczyciela.

W niniejszej pracy pokazano rozwiązanie tych zadań za pomocą modelowania stochastycznego. W procesie modelowania stochastycznego badano wpływ „nieidealnego” nauczyciela i charakterystykę próbki szkoleniowej na wskaźniki efektywności szkolenia.

## Efektywność szkolenia w zarządzaniu potokami transportowymi

Wskaźniki efektywności szkolenia symulacyjnego modelu zarządzania można podzielić na dwie grupy. Do grupy pierwszej należą wskaźniki charakteryzujące jakość reguł decyzyjnych, zbudowanych w etapie szkolenia. Grupę drugą stanowią wskaźniki odnoszące się bezpośrednio do procesu szkolenia i wykorzystywanej próbki szkoleniowej.

Wskaźnikiem charakteryzującym jakość reguł decyzyjnych przyjęto prawdopodobieństwo poprawnej klasyfikacji sytuacji  $P(S)$ , gdzie  $\{S\}$  – zbiór sytuacji. Celem szkolenia symulacyjnego modelu zarządzania jest uzyskanie maksymalnej wartości  $P(S)$ . Analityczne określenie prawdopodobieństwa  $P(S)$  dla realnych próbek szkoleniowych jest stosunkowo trudne. Do jego określenia wykorzystamy egzamin reguł decyzyjnych [4, 5], polegający na ocenie, przez algorytmy klasyfikacji sytuacji, próbki szkoleniowej lub specjalnej próbki egzaminacyjnej. Odpowiedź jest prawidłowa, jeżeli klasyfikacja reguły decyzyjnej jest zgodna z klasyfikacją próbki szkoleniowej. Ocenę prawdopodobieństwa prawidłowej klasyfikacji decyzji w  $r$ -tej sytuacji  $S_r$  można wyrazić następująco:

$$\hat{P}(S_r) = \frac{n_r}{N_r} \quad (1)$$

gdzie:

$n_r$  – liczba poprawnie sklasyfikowanych sytuacji,  
 $N_r$  – liczba egzaminowanych elementów z  $r$ -tej sytuacji  
 $(r = \overline{1, m})$ .

Wtedy wartość średnią  $\hat{E}P(S)$  i odchylenie standardowe  $\sigma^2\{P(S)\}$  można zapisać następująco:

$$\hat{E}P(S) = \frac{1}{m} \sum_{r=1}^m \hat{P}(S_r) \quad (2)$$

$$\sigma^2\{P(S)\} = \left( \frac{\sum_{r=1}^m \hat{P}^2(S)}{m} - (\hat{E}P(S))^2 \right) \frac{m}{m-1} \quad (3)$$

gdzie:

$m$  – liczba sytuacji.

Wskaźniki efektywności szkolenia symulacyjnego modelu zarządzania zależą nie tylko od możliwości nauczyciela, lecz również od mierników próbki szkoleniowej. Można wyróżnić następujące trzy mierniki:

■ losowy wskaźnik bliskości między sytuacjami  $L(S_r, S_l)$ , uwzględniający cechy informacji:

$$L(S_r, S_l) = \sum_{j=1}^M k_j \left| \frac{1}{N_r} \sum_{i=1}^{N_r} x_{ij} - \frac{1}{N_l} \sum_{q=1}^{N_l} x_{iq} \right| \quad (4)$$

gdzie:

$x_{ij}(x_{qi})$  – wartości  $j$ -tej cechy w  $r(l)$ -tej sytuacji ( $i = \overline{1, N_r}$ ;  
 $g = \overline{1, N_l}$ ;  $j = \overline{1, M}$ ;  $r, l = \overline{1, m}; r \neq l$ );

$N_r(N_l)$  – liczba elementów  $r$ -tej ( $l$ -tej) sytuacji w próbie szkoleniowej;  
 $k_j$  – współczynnik wagi, uwzględniający korzyści  $j$ -tej cechy, spełniający warunek  $\sum_{j=1}^M k_j = 1$

■ losowy wskaźnik „rozmiaru sytuacji”  $L(S_r)$ , uwzględniający cechy informacji:

$$L(S_r) = \sum_{j=1}^M \frac{1}{k_j} (X_{rj}^{\max} - X_{rj}^{\min}) \quad (5)$$

gdzie:  
 $X_{rj}^{\max}$  i  $X_{rj}^{\min}$  – maksymalna i minimalna wartość  $j$ -tej cechy  $r$ -tej sytuacji w próbie szkoleniowej;

■ losowy wskaźnik względnej bliskości klas  $\theta(S_r, S_l)$  określony następująco:

$$\theta(S_r, S_l) = \frac{L(S_r) + L(S_l)}{L(S_r, S_l)} \quad (6)$$

**Algorytm szkolenia modelu symulacyjnego z uwzględnieniem „nieidealnego” nauczyciela**

Ogólny schemat blokowy modelu symulacyjnego do badania wpływu „nieidealnego” nauczyciela na proces szkolenia systemu zarządzania pokazano na rysunku 1. W schemacie tym nauczyciel odwzorowany jest za pomocą dwóch bloków: „nauczyciel idealny” i „szkodnik”. Po przeprowadzeniu klasyfikacji mikrosytuacji próbki szkoleniowej przez „nauczyciela idealnego”, „szkodnik” z określonym prawdopodobieństwem wnosi do niej zmiany. Mikrosytuacje określane przez nauczyciela realnego, tj. system „nauczyciel idealny”–„szkodnik”, stanowią dane wejściowe algorytmu szkolenia symulacyjnego modelu zarządzania. „Szkodnik” odwzorowany jest za pomocą generatora liczb losowych o rozkładzie równomiernym w przedziałach (0÷1), operatora przejścia warunkowego i bloku zmiany klasyfikacji pierwotnej. Zmiany klasyfikacji pierwotnej dokonuje się, jeżeli liczba losowa  $i$  uzyskana w  $i$ -tym kroku szkolenia przyjmuje wartość  $\varepsilon(i) \leq P^*$ , gdzie  $P^*$  jest wartością zadanego prawdopodobieństwa błędnej klasyfikacji dokonanej przez nauczyciela realnego.

Po kolejnym kroku szkolenia następuje sprawdzenie warunku zakończenia procesu szkolenia metodą „średniej ruchomej” [6]. Jeżeli warunek jest spełniony, to następuje przejście do bloku „egzamin”, w przypadku przeciwnym – proces szkolenia jest kontynuowany.

Egzamin ocenia jakość szkolenia symulacyjnego modelu zarządzania. W trakcie egzaminu mikrosytuacji ze zbioru  $\{S_l\}$  zostają sklasyfikowane przez nauczyciela „idealnego”(decyzje  $\gamma_l[j]$ ) i przez model zarządzania (decyzje  $\tilde{\gamma}_l[j]$ ). Decyzje  $\gamma_l[j]$  i  $\tilde{\gamma}_l[j]$  są porównywane i po zakończeniu egzaminu, wykorzystując zależności (1) i (2), określa się wartości  $\hat{P}(S_r)$  i  $\hat{E}P(S)$ . Wyniki egzaminu można wyrazić macierzą  $B = \|B_{rl}\|$ , gdzie:

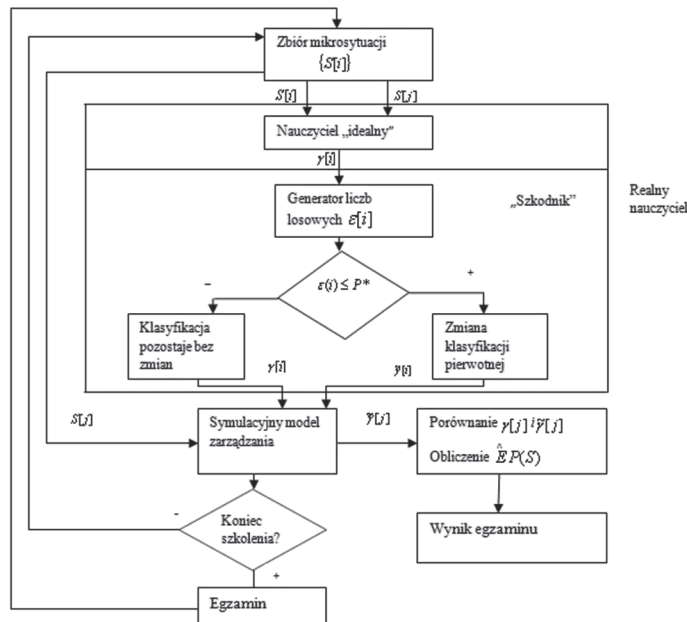
$$B_{rl} = \frac{n_{rl}}{N_r}$$

$n_{rl}$  – liczba mikrosytuacji wydzielonych z  $r$ -tej sytuacji, charakteryzujących  $l$ -tą sytuację,

$N_r$  – liczba elementów  $r$ -tej sytuacji w próbie egzaminacyjnej.

Elementy macierzy  $B$  spełniają warunek:

$$\sum_{l=1}^m B_{rl} = 1$$



Rys. 1. Schemat blokowy szkolenia za pomocą „nauczyciela nieidealnego”

Macierz  $B$  może być również zbudowana w etapie analizy obowiązującego systemu decyzji kierowniczych. W tym przypadku określona ona jest bądź przez decydenta, bądź na podstawie oceny ekspertów.

Podstawą symulacyjnego modelu zarządzania są trzy algorytmy klasyfikacji sytuacji [1]: algorytm oparty na metodzie funkcji potencjałów, algorytm Zigerta-Kotelnikowa i algorytm klasyfikatora liniowego.

W celu dokonania korekty reguł decyzyjnych wymienione algorytmy klasyfikacji poddane są modyfikacji. Korekta reguł decyzyjnych dokonywana jest w trakcie drugiego cyklu szkolenia, z wykorzystaniem informacji o wartościach elementów macierzy  $B$ .

**Badanie wpływu „nieidealności” realnego nauczyciela na proces szkolenia**

W trakcie szkolenia wykorzystano próbkę szkoleniową, której struktura pokazana została w tabeli 1.

Struktura informacji zawartej w tej tabeli odpowiada strukturalnie informacji zawartej w dokumentach statystycznej i operacyjnej sprawozdawczości. Jej wiersze określają mikrosytuacje i decyzje podejmowane w tych mikrosytuacjach, natomiast kolumny – wartości atrybutów (wskaźników charakteryzujących pracę eksploatacyjną rejonu sieci kolejowej).

$X_{ni}^{kr}$  jest wartością  $n$ -tego atrybutu z  $k$ -tego zbioru atrybutów w  $i$ -tej mikrosytuacji ze zbioru  $r$ -tych sytuacji.


Każdy obiekt próbki szkoleniowej charakteryzował się czterema cechami, zaś liczba sytuacji, dla których określono regułę decyzyjną wynosiła dwa.

W pierwszym etapie modelowania symulacyjnego badano wpływ nauczyciela „nieidealnego” na proces szkolenia systemu zarządzania.


W tym celu wykorzystano algorytmy bazowe-rekurencyjne Zigerta-Kotelnikowa i algorytm klasyfikatora liniowego. Wyniki tych badań przedstawiono na rysunku 2 (krzywa 1 dla algorytmu Zigerta-Kotelnikowa, krzywa 2 – dla algorytmu klasyfikatora liniowego).

Tabela korelacji mikro sytuacji i podejmowanych decyzji

Decyzje	Sytuacje	Prawdopodobieństwa mikro sytuacji	Atrybuty									
			Zbiór atrybutów 1			Zbiór atrybutów 2			...	Zbiór atrybutów k		
			$X_1^1$	·	$X_l^1$	$X_1^2$	·	$X_m^2$	...	$X_1^k$	·	$X_n^k$
$\gamma_1$	$S_1$	$q_1^1$	$X_{11}^{11}$	·	$X_{l1}^{11}$	$X_{11}^2$	·	$X_{m1}^2$	...	$X_{11}^k$	·	$X_{n1}^k$
		$q_2^1$	$X_{12}^{11}$	·	$X_{l2}^{11}$	$X_{12}^2$	·	$X_{m2}^2$	...	$X_{12}^k$	·	$X_{n2}^k$
		·	·	·	·	·	·	·	...	·	·	·
		$q_i^1$	$X_{1i}^{11}$	·	$X_{li}^{11}$	$X_{1i}^2$	·	$X_{mi}^2$	...	$X_{1i}^k$	·	$X_{ni}^k$
		·	·	·	·	·	·	·	...	·	·	·
$\gamma_2$	$S_2$	$q_1^2$	$X_{11}^{12}$	·	$X_{l1}^{12}$	$X_{11}^{22}$	·	$X_{m1}^{22}$	...	$X_{11}^{k2}$	·	$X_{n1}^{k2}$
		$q_2^2$	$X_{12}^{12}$	·	$X_{l2}^{12}$	$X_{12}^{22}$	·	$X_{m2}^{22}$	...	$X_{12}^{k2}$	·	$X_{n2}^{k2}$
		·	·	·	·	·	·	·	...	·	·	·
		$q_i^2$	$X_{1i}^{12}$	·	$X_{li}^{12}$	$X_{1i}^{22}$	·	$X_{mi}^{22}$	...	$X_{1i}^{k2}$	·	$X_{ni}^{k2}$
		·	·	·	·	·	·	·	...	·	·	·
$\gamma_r$	$S_r$	$q_1^r$	$X_{11}^{1r}$	·	$X_{l1}^{1r}$	$X_{11}^{2r}$	·	$X_{m1}^{2r}$	...	$X_{11}^{kr}$	·	$X_{n1}^{kr}$
		$q_2^r$	$X_{12}^{1r}$	·	$X_{l2}^{1r}$	$X_{12}^{2r}$	·	$X_{m2}^{2r}$	...	$X_{12}^{kr}$	·	$X_{n2}^{kr}$
		·	·	·	·	·	·	·	...	·	·	·
		$q_i^r$	$X_{1i}^{1r}$	·	$X_{li}^{1r}$	$X_{1i}^{2r}$	·	$X_{mi}^{2r}$	...	$X_{1i}^{kr}$	·	$X_{ni}^{kr}$
		·	·	·	·	·	·	·	...	·	·	·



Rys. 2. Wpływ nauczyciela „nieidealnego” na liczbę kroków szkolenia




Rys. 3. Zależność N od  $L(S_1, S_2)$

W etapie drugim modelowania symulacyjnego badano wpływ mierników próbki szkoleniowej  $\theta(S_1, S_2)$  i  $L(S_1, S_2)$ , określonych wzorami (4) i (6), na proces szkolenia z wykorzystaniem „nauczyciela idealnego”. Wykorzystano przy tym próbkę szkoleniową z różnymi wartościami  $L(S_1, S_2)$ ,  $L(S_1)$  i  $L(S_2)$ .

Zależność liczby kroków szkolenia od wielkości  $L(S_1, S_2)$  pokazano na rysunku 3, natomiast na rysunku 4 – zależność liczby kroków szkolenia od wielkości  $\theta(S_1, S_2)$ . Krzywa 1 dotyczy algorytmu Zigerta-Kotelnikowa, krzywa 2 – algorytmu klasyfikatora liniowego.

Z rysunku 3 wynika, że dla  $L(S_1, S_2) > 5$  szkolenie reguł decyzyjnych kończy się bardzo szybko (20–70 pokazów obiektów




Rys. 4. Zależność N od  $\theta(S_1, S_2)$


z próbki szkoleniowej). Wraz ze spadkiem  $L(S_1, S_2)$  od 5 do 1 zbieżność algorytmów jest bardzo słaba, a przy  $L(S_1, S_2) < 1$  – nieosiągalna.

Można również zaobserwować inną prawidłowość, przy  $L(S_1, S_2) > 2$  wygodnie jest stosować algorytm klasyfikatora liniowego, a przy  $1 \leq L \leq 2$  – algorytm Zigerta-Kotelnikowa. Obszar zastosowania obu algorytmów jest znacznie ograniczony przy  $1 > L \geq 0,5$ , a przy  $L < 0,5$  ich wykorzystanie jest niepożądane, gdyż nie są one zbieżne. Obserwując zależność  $N$  od  $\theta(S_1, S_2)$  (rys. 4) można stwierdzić, że wraz ze wzrostem miernika  $\theta(S_1, S_2)$  szkolenie reguł decyzyjnych wymaga znacznego zwiększenia liczby pokazów obiektów z próbki szkoleniowej; przy  $\theta(S_1, S_2) < 10$  można nie uwzględniać „nieidealności” nauczyciela, przy  $10 \leq \theta(S_1, S_2) < 45$  szkolenie reguł decyzyjnych staje się trudne, a przy  $\theta(S_1, S_2) \geq 45$  – nieosiągalne.


W etapie trzecim wykorzystując macierz  $B$ , przeprowadzono porównanie wyników szkolenia algorytmów bazowych i algorytmów zmodyfikowanych. Wyniki „egzaminu” dla algorytmów: funkcji potencjałów, Zigerta-Kotelnikowa i klasyfikatora liniowego pokazano odpowiednio na rysunkach 5, 6 i 7.



Rys. 5. Prawdopodobieństwo klasyfikacji prawidłowej dla algorytmu funkcji potencjałów bazowego (1) i zmodyfikowanego (2)



Rys. 6. Prawdopodobieństwo kwalifikacji prawidłowej dla algorytmu Zigerta-Kotelnikowa bazowego (1) i zmodyfikowanego (2)



Rys. 7. Prawdopodobieństwo klasyfikacji prawidłowej dla algorytmu klasyfikatora liniowego bazowego (1) i zmodyfikowanego (2)

Z rysunków tych wynika, że algorytmy zmodyfikowane kompensują „nieidealność” nauczyciela realnego. Szczególnie widoczne to jest w przypadku algorytmu Zigerta-Kotelnikowa.

Reasumując można stwierdzić, że wykorzystanie w szkoleniu algorytmów zmodyfikowanych znacznie podwyższa oceny  $\hat{E}P(S)$  w porównaniu z algorytmami bazowymi.

### Zakończenie

Opracowany algorytm identyfikacji sytuacji trudnych, oparty na strukturze reguł decyzyjnych i pojęciu „punktu informacyjnego”, w pełni uwzględnia specyfikę podejmowania decyzji w operatywnym zarządzaniu potokami transportowymi.

Budując model symulacyjny należy ograniczać liczbę atrybutów w procesie podejmowania decyzji. Opracowane podejście do wyboru najbardziej informacyjnych atrybutów w identyfikacji sytuacji oparte jest na pojęciu „cenneści sytuacji”. Częsty brak w praktyce informacji *a priori* można zniwelować za pomocą algorytmu adaptacji i szkolenia lub teorii gier z minimaksymalną zasadą wyboru decyzji.

W procesie podejmowania decyzji decydent może podejmować decyzje nie do końca korzystne, które w procesie szkolenia są zapamiętywane przez model i mogą być wykorzystane w przyszłych sytuacjach wyboru decyzji. W związku z tym powstaje zadanie określenia wpływu „nieidealności” realnego nauczyciela na proces szkolenia. Przeprowadzone obliczenia dla trzech algorytmów: funkcji potencjalnych, Zigerta-Kotelnikowa i klasyfikatora liniowego określiły obszary ich zastosowania i sposoby kompensacji „nieidealności” nauczyciela, oparte na przeprowadzeniu powtórnego cyklu szkolenia i wykorzystaniu wyników egzaminu. □

### Literatura

- [1] Gevarter W.: *An Overview of Expert System*. Washington, D.C. National Bureau of Standards, 1982.
- [2] Kazimierzczak J.: *Teoria gier w cybernetyce*. Wiedza Powszechna. Warszawa 1973.
- [3] Кутыркин А.В., Целяпин В.Н.: *Построение алгоритмов обучения системы управления с учетом «неидеальности» учителя*. Труды МИИТа, выпуск 601, 1978.
- [4] Кутыркин А.В., Михайлов В.В., Шишкин В.М.: *Алгоритм распознавания аварийных ситуаций*. «Энергия», «Электричество», 1971, № 4.
- [5] Кутыркин А.В., Василев В.И.: *Алгоритм принятия решений по оперативному управлению перевозочным процессом при ортогональной структуре решающих правил*. Вестник ВНИИЖТ, 1979, № 4.
- [6] Цыпкин Я.З. *Адаптация, обучение и самообучение в автоматических системах*. Автоматика и телемеханика, 1966, №
- [7] Zieleniewski J.: *Podstawowe pojęcia teorii systemów, organizacji, sterowania i zarządzania*, w pracy zbiorowej: *Współczesne problemy zarządzania*. PWN, Warszawa 1974.

Tadeusz Cisowski  
Wyższa Szkoła Ekonomii i Innowacji w Lublinie  
tadeusz.cisowski@wsei.lublin.pl