ZESZYTY NAUKOWE AKADEMII MARYNARKI WOJENNEJ
ROK LIV NR 3 (194) 2013
DOI: 10.5604/0860889X/1086926

Krzysztof Ficoń
Akademia Marynarki Wojennej
Wydział Dowodzenia i Operacji Morskich
81-103 Gdynia, ul. J. Śmidowicza 69
e-mail: F.Ficon@amw.gdynia.pl

ZASTOSOWANIE ROZMYTYCH STEROWNIKÓW MAMDANIEGO DO OKREŚLANIA RYZYKA WIELOCZYNNIKOWEGO

STRESZCZENIE

W artykule przedstawiono koncepcję wykorzystania teorii zbiorów rozmytych L. A. Zadeha do wyznaczania ryzyka wieloczynnikowego w oparciu o lingwistyczną bazę wiedzy. Docelowy model rozmyty takiego systemu został skonstruowany według uogólnionego standardu sterownika rozmytego zaproponowanego przez E. H. Mamdaniego. We wstępie przedstawiono zarys teorii zbiorów rozmytych Zadeha oraz założenia aplikacyjne rozmytego sterownika Mamdaniego. W dalszej części został zaprezentowany przykładowy model systemu rozmytego służący do wyznaczania ryzyka wieloczynnikowego oparty na regułach logiki rozmytej i funkcjach lingwistycznych. Artykuł stanowi pionierską próbę wykorzystania formalnego aparatu teorii zbiorów rozmytych do wyznaczania ryzyka wieloczynnikowego rozpatrywanego na gruncie standardów bezpieczeństwa pracy.

Słowa kluczowe:
funkcja przynależności, fuzyfikacja, defuzyfikacja, inferencja, logika rozmyta, ryzyko, sterownik rozmyty, wartość lingwistyczna, zbiór rozmyty, zmienna lingwistyczna.

WSTĘP

Jedną z bardziej użytecznych i perspektywicznych metod teoretycznych i narzędziowych ciągle raczkującej sztucznej inteligencji (*Artificial Intelligence*) w ramach węższej koncepcji *Computational Intelligence* zaliczanej do tzw. inteligencji obliczeniowej jest teoria zbiorów rozmytych [5, 7]. Tradycyjnie w zakres

Artificial Intelligence oprócz zbiorów rozmytych zalicza się: sztuczne sieci neuronowe (*Artificial Neural Networks*), algorytmy genetyczne (*Genetic Algorithms*), systemy ekspertowe (*Expert Systems*), a niekiedy także robotykę (*Robotics*). Formalnie za datę powstania *Fuzzy Sets* przyjmuje się rok 1965, kiedy to Lotfi A. Zadeh opublikował w czasopiśmie „Information and Control” przełomowe dzieło pod takim właśnie tytułem — *Fuzzy Sets* [23]. Motywem przewodnim Zadeha była chęć formalnego opisania zjawisk, procesów i obiektów mających charakter wieloznaczny i nieprecyzyjny.

Dotychczasowe metody oparte na klasycznej, dwuwartościowej logice wywodzącej się z czasów starożytnych od Sokratesa, Platona czy Arystotelesa przedstawiają świat tylko w postaci binarnej: jako „prawda” lub „fałsz”. Tymczasem otaczająca nas rzeczywistość to nieskończone spektrum stanów pośrednich, które znacznie łatwiej opisuje się za pomocą wielkości jakościowych niż ilościowych. Nie bez znaczenia jest fakt, że człowiek i jego inteligencja — od zarania swoich dziejów — posługują się znacznie częściej i sprawnej nieostrymi, rozmytymi pojęciami jakościowymi, które najczęściej obrazują pewne zakresy (przedziały) wartości kontekstowych [1, 9, 11]. Klasyczna, dwuwartościowa logika jest ciągle niekwestionowanym paradygmatem współczesnej nauki, której naczelną misją jest *de facto* dochodzenie do prawdy albo odkrywanie obiektywnych (naturalnych, prawdziwych) praw przyrody. Symbolami logiki klasycznej są przykładowo takie stwierdzenia, jak: „2 + 2 = 4”, „0 lub 1”, „tak lub nie”, „dzień lub noc”, „białe lub czarne”, „prawda lub fałsz”.

Teoretycznym rozważaniom L. Zadeha prakseologiczny impuls nadała dopiero utylitarna koncepcja rozmytych sterowników zaproponowana przez E. H. Mamdaniego [12, 13]. Należy zauważyć, że do przełomowego wdrożenia sterowników Mamdaniego nauka podchodziła dość sceptycznie, zwłaszcza nauki techniczne i sztuka inżynierska dystansowały się wobec wszelkich aplikacji zawierających wielkości nieostre czy parametry nieprecyzyjne. Sterowniki rozmyte realizują tzw. wnioskowanie rozmyte, które może być prowadzone albo na podstawie precyzyjnych danych analitycznych (np. pomiarowych), albo na podstawie nieostrych zmiennych lingwistycznych, pochodzących na przykład z eksperckiej bazy wiedzy. Zawsze jednak ich działaniem steruje określony zbiór reguł logiki rozmytej, implementowany w strukturze odpowiedniej bazy wiedzy. Regułową koncepcję sterowników Mamdaniego wyraźnie rozszerzyli Takagi i Sugeno [20], wprowadzając dodatkowo na etapie definiowania konkluzji bardziej uniwersalne zależności funkcyjne. Dzięki rozmytym modelom Mamdaniego i Takagi-Sugeno teoria zbiorów rozmytych i będąca jej aparatem formalnym logika rozmyta stworzyły nową dziedzinę aplikacji między innymi w naukach technicznych zaliczaną powszechnie do kategorii *Fuzzy*.

Sterowniki rozmyte (*Fuzzy Logic Controller*) należą dziś do standardowego wyposażenia wielu instalacji, obiektów i urządzeń technicznych, począwszy od szerokiego asortymentu sprzętu AGD (klimatyzatory, pralki, kuchenki mikrofalowe, odbiorniki telewizyjne), poprzez sterowniki montowane w środkach transportowych (samoloty, samochody, statki), duże urządzenia dźwigowe i suwnice portowe, aż do skomplikowanych systemów chłodzenia w elektrowniach atomowych, sterowania turbinami i agregatami prądotwórczymi czy sterowania czynnikiem produkcyjnym w instalacjach chemicznych i przemysłowych [9, 14].

Obszar technicznych zastosowań sterowników rozmytych ciągle się poszerza. Ostatnio dołączyły do niego zastosowania nietechniczne: w medycynie, ekonomii, handlu, a także w sferze zarządzania i kierowania różnymi procesami gospodarczo-społecznymi. Przykładem takiej aplikacji jest prezentowana w niniejszym artykule koncepcja wykorzystania modeli rozmytych *Fuzzy* do sterowania (zarządzania) bezpieczeństwem systemowym, determinowanym poziomem ryzyka [6].

Równie wielkie szanse dla logiki i teorii zbiorów rozmytych upatrują dziś specjaliści od nauk kognitywnych, które bezpośrednio decydują o stanie badań nad różnymi aspektami sztucznej inteligencji [7, 11]. Naturalna, ludzka inteligencja tylko sporadycznie posługuje się precyzyjnym językiem sformalizowanym, a znacznie częściej nieostrym, kontekstowym rozumowaniem i wieloznacznym, werbalnym przekazem. Gatunek *Homo sapiens* z naturalnym polotem operuje jakościowym systemem pojęć, różnych analogii i porównań, budując rozmyte konstrukcje myślowe o wielkim bogactwie przekazywanej informacji [11].

WYBRANE ELEMENTY TEORII ZBIORÓW ROZMYTYCH

Kluczowym pojęciem teorii *Fuzzy* jest pojęcie zbioru rozmytego, który formalnie opisuje narzędziowy aparat logiki rozmytej. Konwencja zbiorów rozmytych jest powszechnie stosowana przez ludzi do jakościowej oceny różnych wielkości fizycznych, zjawisk przyrodniczych i procesów społecznych [14, 18]. Przykładowo temperaturę powietrza na co dzień oceniamy jako „zimno”, „ciepło”, „gorąco”, dodatkowo stopniując te wartości. Podobnie wzrost człowieka — „mały”, „średni”, „wysoki”; prędkość samochodu — „mała”, „średnia”, „duża”; urodę osób — „brzydka”, „pospolita”, „ładna”, „piękna”; stan domowych finansów — „krytyczny”, „normalny”, „zadawalający” „dobry”; nastrój wewnętrzny — „stres”, „chandra”, „radość”, „euforia” itp. Świat zbiorów rozmytych jest praktycznie nieskończony, gdyż wiąże się bezpośrednio z ludzką świadomością, inteligencją i komunikacją, zwłaszcza werbalną. Różnice i analogie między formalnymi zbiorami klasycznymi i znacznie bardziej popularnymi zbiorami rozmytymi zostały przedstawione na rysunku 1.

Zanim wprowadzimy pojęcie zbioru rozmytego, zdefiniujemy jego elementy pomocnicze, takie jak zmienna (X), wartość (x) i przestrzeń lingwistyczna (Π) [14]:

$$\Lambda = \langle X, x, \Pi \rangle, \tag{1}$$

gdzie:

X — zmienna lingwistyczna — wyrażone w języku naturalnym określenie pewnej wielkości (stanu, procesu, wejścia, wyjścia), np. temperatury, wzrostu, prędkości, urody, ciśnienia, charakteru itp.;

x — wartość zmiennej lingwistycznej — określona w języku naturalnym cecha, najczęściej wartościująca (stopniowalna) tej zmiennej np. „zimno”, „gorąco”, „niska”, „średnia”, „wysoka”, „mały”, „duży”, „wielki”, „zły”, „obojętny”, „dobry”, „prawdziwy”, „fałszywy”;

Π — przestrzeń lingwistyczna — zbiór wszystkich możliwych wartości lingwistycznych stosowanych do oceny danej zmiennej lingwistycznej.

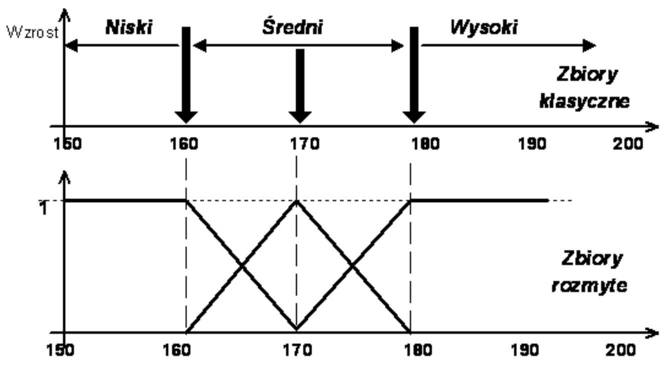

Rys. 1. Graficzna interpretacja zbiorów klasycznych i rozmytych dla „wzrostu”

Źródło: opracowanie własne.

Wartości lingwistyczne występują w modelach wraz ze zmiennymi, których dotyczą, na przykład „wysoka temperatura”, „młody człowiek”, „nieprawdziwa informacja”, „prawdziwy przyjaciel”. Zmienna lingwistyczna, np. temperatura, może przyjmować zarówno wartości liczbowe, np. 35°C, jak też wartości lingwistyczne (jakościowe), np. „wysoka”, „niska”, „gorąco”, „zimno”. Wartości lingwistyczne z jednej strony są charakterystyczne dla ludzkiego języka i sposobu porozumiewania się, z drugiej są utożsamiane semantycznie z pewnymi zbiorami rozmytymi. Z prostych jednowyrazowych wartości lingwistycznych na bazie wielowartościowej logiki rozmytej — stosując odpowiednie operatory logiczne — można utworzyć bardziej złożone wyrażenia lingwistyczne, np. „mniej więcej dobrze”, „nie bardzo wysoka, ale i nie bardzo niska”, „średnia jest zbyt wysoka” [18, 19].

Zgodnie z teorią Carnota zbiór klasyczny B, który formalnie nie podlega definiowaniu, jest opisywany za pomocą tzw. funkcji charakterystycznej φ_B, która każdemu elementowi $x \in X$ zbioru przyporządkowuje liczbę 0 lub 1 [16]:

$$\varphi_B \colon X \to \{0,1\}, \tag{2}$$

przy czym:
$\varphi_B = 0$ — element x nie należy do zbioru B;
$\varphi_B = 1$ — element x należy do zbioru B.

W zbiorze klasycznym (2) mamy ostre przejście od elementów należących do zbioru do elementów nienależących do zbioru, tzn. przejście od przynależności do nieprzynależności jest skokowe. Pojęcie zbioru rozmytego jest uogólnieniem pojęcia zbioru klasycznego (ostrego), polegającym na tym, aby funkcja charakterystyczna (przynależności) zbioru przyjmowała obok stanów krańcowych {0,1} także wartości pośrednie z całego przedziału zmienności [0,1].

Zbiorem rozmytym A w pewnej niepustej, numerycznej przestrzeni rozwiązań X = {x} nazywamy zbiór uporządkowanych par [23, 14, 18]:

$$A = \{(x, \mu_A(x)\}; \ \ x \in X \tag{3}$$

gdzie:
$x \in X$ — element przestrzeni X;

$\mu_A(x)$ — funkcja przynależności zbioru rozmytego A, która każdemu elementowi $x \in X$ przyporządkowuje stopień jego przynależności $\mu_A(x)$.

Istnieją zbiory, w przypadku których określenie przynależności danego elementu nie jest jednoznaczne, np. zbiór młodych ludzi, zbiór wysokich drzew, zbiór szybkich samochodów, zbiór ciekawych książek itp. W przypadku takich zbiorów możemy mówić wyłącznie o stopniu przynależności danego elementu, w tym sensie można powiedzieć, że osoba w wieku trzydziestu lat należy do zbioru młodych ludzi w większym stopniu niż osoba w wieku sześćdziesięciu lat.

Funkcja przynależności μ_A realizuje odwzorowanie przestrzeni X danej zmiennej x do przedziału liczb rzeczywistych [0,1]:

$$\mu_A\colon X \to [0,1], \text{ przy czym: } \mu_A(x) \in [0,1] \tag{4}$$

Inaczej mówiąc, funkcja przynależności przyporządkowuje każdemu elementowi x danej zmiennej X pewną wartość z zakresu [0,1] — liczbę rzeczywistą. Wartość ta, zwana stopniem przynależności, informuje, w jakim stopniu element x należy do zbioru rozmytego A, przy czym można wyróżnić trzy przypadki przynależności [18]:

$\mu_A(x) = 1$ — pełna przynależność elementu x do zbioru rozmytego A, tzn. $x \in A$;
$0 < \mu_A(x) < 1$ — częściowa przynależność elementu x do zbioru rozmytego A;
$\mu_A(x) = 0$ — brak przynależności elementu x do zbioru rozmytego A, tzn. $x \notin A$.

Jeśli funkcja przynależności przyjmuje tylko dwie wartości: „0” i „1”, to zbiór rozmyty A jest zbiorem klasycznym B. Funkcja przynależności μ_A redukuje się wówczas do funkcji charakterystycznej zbioru klasycznego φ_B.
Przykładowe zbiory klasyczne i rozmyte zostały przedstawione na rysunku 2.

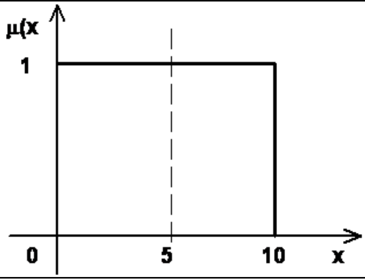	Zbiór klasyczny $\mu(x) = \begin{cases} 1; & x \in [0,10] \\ 0; & x \notin [0,10] \end{cases}$
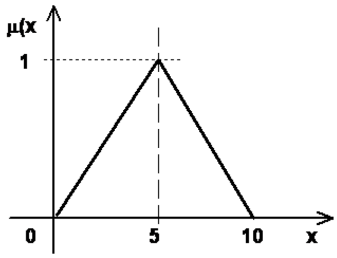	Zbiór rozmyty $\mu(x) = \begin{cases} 1 - \dfrac{\lvert x-5 \rvert}{5}; & x \in [0,10] \\ 0; & x \notin [0,10] \end{cases}$

Rys. 2. Graficzna interpretacja zbioru klasycznego i zbioru rozmytego

Źródło: opracowanie własne.

W przypadku zbiorów rozmytych (2) przejście od przynależności do nieprzynależności jest stopniowe i może być dostatecznie ciągłe. Wobec tego elementy zbioru rozmytego A mogą do niego należeć do pewnego stopnia — od pełnej przynależności do nieprzynależności przez wszystkie stopnie pośrednie. Formalnie właściwość tę L. Zadeh [22] osiągnął poprzez zastąpienie skokowej funkcji charakterystycznej (1) stopniowalną funkcją przynależności (3):

$$\varphi_B\colon X \to \{0,1\} \text{ — klasyczne } \Rightarrow \mu_A\colon X \to [0,1] \text{ — rozmyte} \tag{5}$$

Pojęcie zbioru rozmytego (2) pozwala na formalne definiowanie pojęć nieostrych, np. jakościowych czy stopniowalnych i odnoszenie ich do znaczeń kontekstowych. Należy jednak pamiętać, że funkcja przynależności (3) jest wysoce subiektywna, w przeciwieństwie do formalnej funkcji charakterystycznej (1). Ale to powinno być normalne, bo celem zbiorów rozmytych jest określanie jakościowych, nieostrych pojęć rozmytych, często intuicyjnych i subiektywnych. Pojęcie zbioru rozmytego (2) umożliwia matematyczne sformułowanie zapisu wartości lingwistycznych i liczb rozmytych stosowanych obiegowo przez ludzi.

Funkcja przynależności zgodnie ze wzorem (3) opisuje stopień, w jakim dany element x należy do zbioru rozmytego A. Może być dowolną funkcją odwzorowującą obszar X na przedział domknięty [0,1]. Z uwagi na arbitralny charakter funkcji przynależności w praktyce występuje wiele różnych typów tej funkcji, a do najczęściej używanych należą funkcje: trójkątne, trapezowe, sigmoidalne, Guassowska, klasy L i Π [14, 19]. Funkcja przynależności jest najczęściej wyrażana za pomocą wykresu, tabeli, a także wzoru matematycznego. Najbardziej popularna funkcja trapezowa [14] stosowana także w sterownikach Mamdaniego jest opisywana za pomocą następującego wyrażenia (rys. 3.):

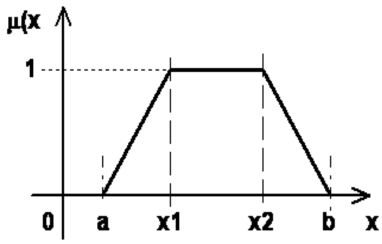

$$\mu_A(x) = \begin{cases} \dfrac{x-a}{x_1-a} & a \le x \le x_1 \\ 1 & x_1 \le x \le x_2 \\ \dfrac{b-x}{b-x_2} & x_2 \le x \le b \\ 0 & \text{dla pozostałych } x \end{cases}$$

Rys. 3. Trapezowa funkcja przynależności elementu x do zbioru A

Źródło: opracowanie własne.

Na zbiorach rozmytych, podobnie jak na zbiorach klasycznych, wykonuje się szereg różnych operacji logiczno-arytmetycznych, takich jak np. suma, iloczyn, dopełnienie [18, 19]:

$\mu_{A \cup B} = \mathrm{MAX}(\mu_A(x), \mu_B(x))$	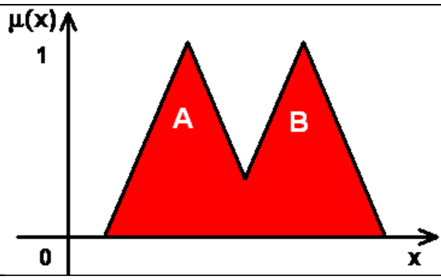
$\mu_{A \cap B} = \mathrm{MIN}(\mu_A(x), \mu_B(x))$	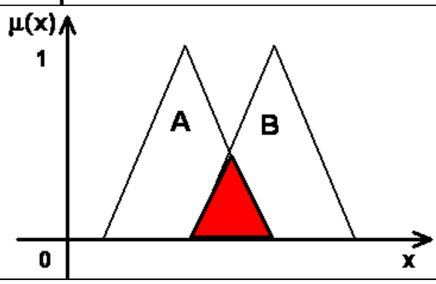

$\mu_B(x) = 1 - \mu_A(x)$	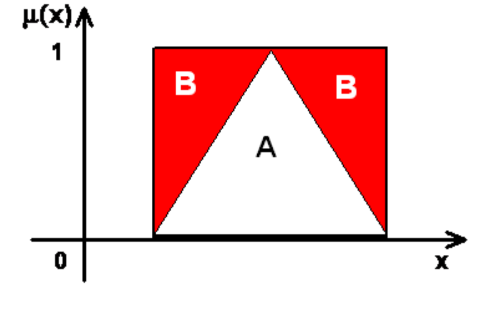

Rys. 4. Przykładowe operacje na zbiorach rozmytych

Źródło: opracowanie własne.

Operatory MAX i MIN nie są jedynymi stosowanymi w operacjach przecięcia i połączenia zbiorów rozmytych. W ogólności przecięcie zbiorów rozmytych A i B jest definiowane jako [14]:

$$\mu_{A \cap B} = T\big(\mu_A(x), \mu_B(x)\big) = T(A, B), \tag{6}$$

gdzie funkcja dwóch zmiennych $T(A, B)$ nazywana jest normą trójkątną lub T-normą. Analogicznie jak przecięcie definiowane jest połączenie dwóch zbiorów rozmytych A i B:

$$\mu_{A \cup B} = S\big(\mu_A(x), \mu_B(x)\big) = S(A, B), \tag{7}$$

gdzie funkcja $S(A, B)$ nazywana jest S-normą lub T-normą. Opisany powyżej operator MAX jest przykładem S-normy, a innym jej przykładem jest suma algebraiczna, którą zapisujemy jak poniżej:

$$\mu_{A \cup B} = \mu_A(x) + \mu_B(x) - \mu_A(x) \times \mu_B(x). \tag{8}$$

Na szczególną uwagę zasługują relacje rozmyte, które pozwalają nieprecyzyjnie wyrazić zależności między elementami pewnych zbiorów. Siła poszczególnych relacji rozmytych zawiera się w przedziale [0,1], przy czym 1 oznacza, że elementy są w pełnej relacji, 0 — brak takiej relacji, a pozostałe wartości — wszystkie przypadki pośrednie.

IDEA STEROWNIKA MAMDANIEGO

Przełomowym wydarzeniem dla rozwoju systemów rozmytych były prace teoretyczno-konstrukcyjne brytyjskiego inżyniera Ebrahima Mamdaniego, w wyniku których w 1970 roku powstał tzw. sterownik Mamdaniego, oznaczający rewolucję w automatyce i teorii sterowania [12, 13]. Mamdani zastosował teorię Zadeha do dynamicznego sterowania obiektami za pomocą modelu człowiek-operator (regulator) sterujący obiektem fizycznym. Z uwagi na dużą prostotę i skuteczność działania spotkał się z powszechnym zainteresowaniem i licznymi aplikacjami.

Modele Mamdaniego stosują najbardziej naturalne z punktu widzenia logiki rozmytej podejście, ponieważ opierają się na bazie reguł i stosowaniu operatorów lingwistycznych. W przypadku modelu Mamdaniego funkcja przynależności rozmytej implikacji $A \Rightarrow B$, która jest równoważna pewnej relacji rozmytej $R \subseteq X \times Y$, wyznaczamy następująco [13]:

$$\mu_{A \Rightarrow B}(x, y) = T(\mu_A(x), \mu_B(x)), \tag{9}$$

gdzie:
T – dowolna T-norma, np. MIN lub iloczyn.

Regułę Mamdaniego cechuje duża prostota i intuicyjna łatwość aplikacji. Modelowany system traktuje ona jako cybernetyczną czarną skrzynkę odznaczającą się brakiem informacji o zjawiskach fizycznych zachodzących wewnątrz. Znane są jedynie relacje między sygnałem wejściowym i wyjściowym. Celem jej działania jest opracowanie takiego modelu logicznego lub matematycznego, który będzie realizował odwzorowanie zbioru (wektora) wejść w zbiór (wektor) wyjść. Formalnie model Mamdaniego jest zbiorem reguł lingwistycznych, z których każda definiuje jeden punkt w rozmytej przestrzeni stanów wyjściowych.

Reguły występujące w modelu Mamdaniego to specyficzne reguły rozmytej logiki Zadeha łączące zbiór przesłanek sygnałów wejściowych ze zbiorem konkluzji traktowanym jako zbiór wyjściowy. Istotnym elementem tego modelu jest rodzaj użytego operatora logicznego łączącego przesłanki wejściowe w sygnał wyjściowy. Początkowo w modelach Mamdaniego były stosowane niemal wyłącznie wartości (etykiety) lingwistyczne typu „mały — duży”, „zimny — ciepły”, „wysoki — niski” [12].

W przypadku dużej liczby powstających zbiorów rozmytych rosła liczba etykiet lingwistycznych typu „prawie mały", „średnio mały", „prawie średni", „średni, prawie duży", „duży". Lepszym rozwiązaniem okazało się stosowanie liczbowych etykiet rozmytych typu: „około 1", „około 3", „mniej niż 2", „ponad 5" itp. Modele rozmyte z etykietami w formie liczb rozmytych określane są mianem nielingwistycznych [14].

W logice klasycznej opracowano wiele sposobów wnioskowania zwanych tautologiami, z których najbardziej znana to *Modus Ponens*. Dla potrzeb modelowania rozmytego wnioskowanie przybliżone oparte jest na zmodyfikowanej tautologii nazywanej *Uogólniony Modus Ponens* [18]. Mechanizm inferencyjny realizuje główne zadanie i oblicza wynikową funkcję przynależności wyjścia. Przykładowo dla dwuwejściowego modelu Mamdaniego reguły te mają ogólną postać:

$$\text{IF } (x_1 \text{ IS } A_1) \text{ AND/OR/NOT } (x_2 \text{ IS } A_2) \text{ THEN } (y \text{ IS } C), \tag{10}$$

gdzie:

x_1, x_2, y — zmienne lingwistyczne;

A_1, A_2, C — zbiory rozmyte reprezentujące określone wartości zmiennych lingwistycznych x_1, x_2, y.

Wnioskowanie według reguł Mamdaniego jest wykorzystywane głównie w układach regulacji, gdzie reguły dają wyrażenia lingwistyczne strategii sterowania oparte na znajomości eksperckiej systemu i zdrowym rozsądku. Dopiero przełomowa teoria i praktyczna aplikacja przemysłowa sterowników Mamdaniego oraz będących ich rozszerzeniem modeli Takagi-Sugeno [20] wzbudziła szerokie zainteresowanie świata nauki i, co najważniejsze, podmiotów komercyjnych Zadehowską teorią zbiorów rozmytych. Komercyjny impuls dla praktycznych teorii i systemów *Fuzzy* nadali Japończycy, a najbardziej spektakularnym sukcesem okazało się zastosowanie sterowników rozmytych przez firmę Hitachi do sterowania metrem w Sendai na Hokaido. Układ ten automatycznie zmniejszał prędkość metra przy wjeździe na stację i zapewniał dokładne zatrzymanie w wyznaczonym miejscu oraz wysoki komfort jazdy dzięki łagodnemu przyspieszaniu i hamowaniu. Układ sterujący metrem w Sendai został zaprojektowany na bazie heurystycznej wiedzy doświadczonego maszynisty [9, 14].

W przypadku najbardziej popularnego systemu rozmytego zawierającego dwa wejścia i jedno wyjście dobór reguł wnioskowania można wstępnie zaplanować za pomocą dwuwymiarowej macierzy decyzyjnej, której współrzędnymi są zmienne wejściowe x_1 oraz x_2 (przesłanki), a elementami macierzy projektowane konkluzje $y(x_1,x_2)$.

MODELE I SYSTEMY ROZMYTE

Zbiory rozmyte oraz ich aparat formalny w postaci logiki rozmytej pozwala na budowanie teoretycznych i prakseologicznych modeli i różnych systemów rozmytych, mających duży walor utylitarny. Główną zaletą modeli rozmytych względem konwencjonalnych modeli matematycznych jest możliwość konstruowania ich w oparciu o znacznie mniejszą informację o badanym systemie. Na dodatek informacja ta może mieć charakter niepewny, rozmyty i nieprecyzyjny [1, 9]. Funkcjonowanie systemów rozmytych polega na przetworzeniu wejściowych zmiennych ilościowych na pojęcia lingwistyczne, następnie modelowaniu systemu na podstawie bazy reguł, która może odzwierciedlać naszą wiedzę o systemie. Na koniec wyjściowe sygnały (zbiory) rozmyte są przetwarzane z powrotem na zmienne ilościowe. Konceptualna struktura typowego modelu rozmytego obejmuje trzy główne bloki [9]: fuzyfikacji (rozmywania), inferencji (wnioskowania) i defuzyfikacji (ostrzenia) (rys. 5.).

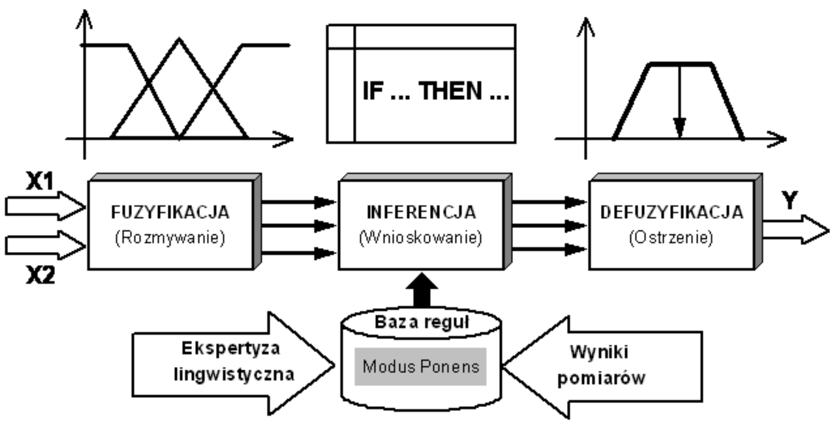

Rys. 5. Schemat systemu (sterownika) rozmytego

Źródło: opracowanie własne.

Startowy blok fuzyfikacji wykonuje operację tzw. rozmywania, czyli wyznaczania stopnia przynależności dla wejściowych zbiorów rozmytych. Fuzyfikacja polega na przekształcaniu pojedynczych sygnałów wejściowych, np. liczb, na wielkości jakościowe reprezentujące zbiory rozmyte. Aby wykonać tę operację blok fuzyfikacji musi mieć dokładnie zdefiniowane funkcje przynależności dla wszystkich wejściowych zbiorów rozmytych. W przypadku wielu wejść $x_i \in X$ w procesie fuzyfikacji ich wartości ostre (np. liczbowe) zostają przekształcone w wektor stopni przynależności $\mu_j(x_i) \in B_i$, obrazujący określone zbiory rozmyte $B_i \in B$:

$$x_i \in X \implies \mu_j(x_i) \in B_i; \quad i = \overline{1, I}, \quad j = \overline{1, J}. \tag{11}$$

Obliczone przez blok fuzyfikacji wartości stopni przynależności poszczególnych wejść $\mu_j(x_i)$ są podstawą pracy bloku inferencji (wnioskowania), który oblicza wynikową funkcję przynależności wyjścia z modelu. Blok inferencji oblicza na podstawie wejściowych stopni przynależności $\mu_j(x_i)$ tzw. wynikową funkcję przynależności wyjścia $\mu_C(y)$:

$$\mu_j(x_i) \in B_i \implies \mu_C(y); \quad i = \overline{1, I}, \quad j = \overline{1, J}. \tag{12}$$

Aby możliwe było przeprowadzenie obliczeń inferencyjnych, blok ten powinien zawierać takie elementy, jak baza reguł, mechanizm inferencyjny i funkcje przynależności wyjścia z modelu. Kluczowa baza reguł zawiera reguły logiczne określające zależności przyczynowo-skutkowe istniejące między zbiorami rozmytymi wejścia i wyjścia. Istotnym problemem jest sposób tworzenia reguł wnioskowania. Modelowanie systemów rozmytych (nieostrych) jest realizowane za pomocą dwóch zasadniczych metod bazujących albo na wiedzy eksperta, jako tzw. modelowanie lingwistyczne, albo na danych analitycznych pochodzących bądź z systemów pomiarowych, bądź z modeli matematycznych [14].

Historycznie pierwszym rodzajem modelowania rozmytego zastosowanym w praktyce było modelowanie na bazie heurystycznej wiedzy eksperta, która za pomocą specjalnych interfejsów była transformowana do postaci zmiennych lingwistycznych i dalej do struktur zbiorów rozmytych [14]. Zadaniem eksperta będzie zarówno konstrukcja samej reguły wnioskowania, jak i dobór funkcji przynależności dla każdego przypadku. Zasadniczą zaletą lingwistycznych modeli rozmytych względem konwencjonalnych modeli matematycznych stosowanych znacznie wcześniej, głównie w automatyce i sterowaniu, jest możliwość ich skonstruowania na bazie znacznie mniejszej liczby informacji o badanym systemie rzeczywistym. Ponadto informacja ta może mieć charakter nieprecyzyjny, rozmyty i niepewny.

Wielkością wyjściową z bloku wnioskowania jest bądź N zbiorów rozmytych B_i z funkcjami przynależności $\mu_{Bi}(y)$, i = 1, 2, …, N, bądź jeden zbiór rozmyty B' z funkcją przynależności $\mu_B(y)$. Zawsze pojawia się problem odwzorowania tych zbiorów rozmytych w jedną wartość liczbową $y \in Y$, która będzie wartością odpowiedzi rozmytego systemu wnioskowania po podaniu na jego wejście sygnałów $x \in X$.

W wyjściowym bloku defuzyfikacji na podstawie wynikowej funkcji przynależności wyjścia obliczana jest ostra (liczbowa) wartość sterująca, będąca skutkiem podania ostrych wartości wejściowych. Operacja ta jest realizowana przez mechanizm defuzyfikacji, który zawiera sposób przeprowadzenia obliczeń. W tym celu stosuje się takie metody, jak środek maksimum, pierwsze maksimum, ostatnie maksimum, środek ciężkości, metoda wysokości [1]. Spośród wielu różnych reguł dużą popularnością cieszy się metoda środka ciężkości (*Center of Gravity Method*), która będzie użyta w prezentowanym przykładzie:

$$y = {\sum_{k=1}^{N} \mu_B(y_k) \cdot y_k} \Big/ {\sum_{k=1}^{N} \mu_B(y_k)} \, . \tag{13}$$

Wyostrzanie (13) ma na celu przekształcanie wynikowego zbioru rozmytego na ostrą wartość rzeczywistą stanowiącą wartość wyjściową modelu, będącą np. sygnałem sterującym albo inną zmienną decyzyjną.

PRZYKŁAD WYZNACZANIA RYZYKA WIELOCZYNNIKOWEGO

Praktyczne wykorzystanie teorii zbiorów rozmytych bazującej na modelu Mamdaniego i bazie wiedzy eksperckiej zilustrowano na przykładzie systemu wyznaczania tzw. ryzyka wieloczynnikowego, rozpatrywanego ze względu na trzy prognozowane czynniki (argumenty): kategorię zagrożeń, wielkość strat materialnych, szacunkowe straty moralne (sanitarne) [2, 17]. Praktyka i teoria szacowania ryzyka, będącego praktycznie jedynym argumentem mierzalnym przy wyznaczaniu wielkości bezpieczeństwa, wskazuje, że zarówno ryzyko, jak i sam termin bezpieczeństwo jest powszechnie wyrażany w rozmytym ujęciu jakościowym [3, 4]. Ryzyko wystąpienia np. sytuacji kryzysowej jest zmienną lingwistyczną, która może przyjmować trzy wartości rozmyte: „małe” (akceptowane), „średnie”(dopuszczalne), „duże”(niedopuszczalne).

Przedmiotem naszych rozważań jest tzw. ryzyko obliczeniowe (R) powszechnie wyrażane za pomocą prostego iloczynu [10]:

$$R = p \times S \to \Re^{+}, \tag{14}$$

gdzie:
R — ryzyko obliczeniowe;
P — prawdopodobieństwo wystąpienia zdarzenia krytycznego;
S — szacowane negatywne skutki i następstwa zdarzenia krytycznego;
$\Re^{+}$ — zbiór liczb rzeczywistych.

Klasyczna definicja ryzyka (14) traktuje ryzyko jako multiplikatywną funkcję prawdopodobieństwa $0 < p < 1$ oraz wymiernych skutków $S \to \Re^{+}$ wyrażonych za pomocą liczb rzeczywistych [4, 10]. Dla potrzeb artykułu definicja ryzyka (13) zostanie zmodyfikowana pod kątem standardów stosowanych w sferze bezpieczeństwa pracy [2, 15]. Większość wykorzystywanych metod i standardów w zakresie oceny tzw. ryzyka zawodowego bazuje na znacznie bardziej rozbudowanych formułach niż klasyczna jego definicja. W obszarze oceny ryzyka zawodowego stosuje się między innymi różne metody wieloczynnikowe, takie jak [6]:

1. *Risk Score* — metoda trójczynnikowa, której argumentami są: prawdopodobieństwo zdarzenia, możliwe skutki i następstwa, ekspozycja na zagrożenia.
2. *Five Steps* — metoda czteroczynnikowa, której argumentami są: prawdopodobieństwo zdarzenia, następstwa i skutki, częstotliwość narażenia, liczba osób narażonych.
3. *Job Safety Analysis* — metoda trójczynnikowa, której argumentami są: prawdopodobieństwo zdarzenia, częstotliwość zagrożeń, możliwość uniknięcia lub ograniczenia szkody.

4. Graf ryzyka — metoda czteroczynnikowa, której argumentami są: prawdopodobieństwo zdarzenia, wielkość szkód i strat, czas występowania zagrożenia, możliwość zastosowania ochrony przed zagrożeniem.
5. Wskaźnik ryzyka — metoda czteroczynnikowa, której argumentami są: prawdopodobieństwo zdarzenia, częstość występowania, rodzaj szkody, zakres i skala szkody.

Punktem wyjścia do budowy przykładowego modelu jest określenie zasadniczych czynników badanego ryzyka, które wyznaczać będą jego realny poziom, odnoszony z reguły do umownej skali wartościowania. W modelu przyjęto trójczynnikową formułę szacowania ryzyka, zwanego dalej ryzykiem wieloczynnikowym [15]:

$$R = f(ZG, S\$, SM), \tag{15}$$

gdzie:
ZG — umownie przyjęta kategoria zagrożeń;
S$ — prognozowany poziom strat i szkód materialnych;
SM — prognozowany poziom strat moralnych (osobowych).

Celowo pominięto klasyczny czynnik — występujący w każdej definicji obliczeniowej ryzyka (14) — prawdopodobieństwo zaistnienia zdarzenia krytycznego (zagrożenia), gdyż jest to zmienna typowo losowa, która powinna być wyznaczana na podstawie badań statystycznych, co nie zawsze w teorii bezpieczeństwa jest możliwe [10]. Częściowo element prawdopodobieństwa został zawarty w procedurze kategoryzacji zagrożeń.

Każdy z trzech wytypowanych czynników ryzyka charakteryzowany jest za pomocą odpowiednich zmiennych lingwistycznych, którym zostaną przypisane stosowne wartości lingwistyczne [4]. Sposób wnioskowania rozmytego w oparciu o bazę wiedzy eksperta zilustrowano na przykładzie modelu zawierającego tylko trzy zmienne lingwistyczne utożsamiane w tym przypadku z trzema czynnikami ryzyka. Dla uproszczenia rozważań przyjmiemy założenie, że wszystkie czynniki ryzyka będą wartościowane za pomocą trzech zmiennych lingwistycznych, których wartości lingwistyczne i statystyczne zostały przedstawione w tabeli 1.

Tabela 1. Przykładowe wartości lingwistyczne i statystyczne
wyodrębnionych czynników ryzyka

WARTOŚCI / CZYNNIKI	Wartości czynników ryzyka		
	lingwistyczna M — małe statystyczna	**lingwistyczna E — średnie statystyczna**	**lingwistyczna D — duże statystyczna**
Kategoria zagrożeń	normalne 0 ≤ Z ≤4	niespodziewane 3 ≤ Z ≤8	krytyczne Z ≥ 7
Straty materialne	niskie $ ≤ 2.000	średnie 1.000 ≤$ ≤11.000	wysokie $ ≥ 10.000
Straty moralne	akceptowane Q ≤ 3	nieakceptowane 2 ≤ Q ≤ 6	katastroficzne Q ≥ 5
Wartości lingwistyczne i statystyczne ryzyka			
Ryzyko	akceptowane 0 ≤ R ≤ 0,4	dopuszczalne 0,3 ≤ R ≤0,8	niedopuszczalne R ≥ 0,7

Źródło: opracowanie własne.

Graficzne zobrazowanie poszczególnych zmiennych lingwistycznych i odpowiadających im zbiorów rozmytych wraz z funkcjami przynależności przedstawiono na rysunkach 6. i 7.

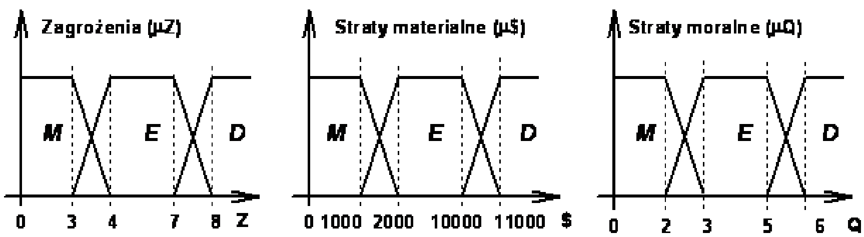

Rys. 6. Funkcje przynależności zmiennych lingwistycznych µ(Z), µ($), µ(Q)

Źródło: opracowanie własne.

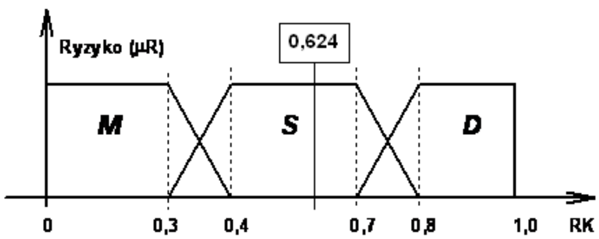

Rys. 7. Funkcja przynależności zmiennej lingwistycznej ryzyko µ(Z)

Źródło: opracowanie własne.

W praktyce najczęściej stosuje się tzw. trapezowe liczby rozmyte, których wartości wyznaczają następujące parametry: (a, x_1, x_2, b) – tabela 1. Jeśli $x_1 = x_2$, otrzymujemy trójkątną liczbę rozmytą. Granice i zakresy przedziałowe trapezowej liczby rozmytej mają bardzo prostą interpretację praktyczną. Granice wewnętrzne tworzą odcinek [x_1, x_2] na pewno zawierający nieznaną dokładną wartość. Granice zewnętrzne [a, x_1] i [x_2, b] zawierają nieznaną wartość tylko w pewnym sensie — zgodnie z jej funkcją przynależności do zbioru rozmytego [18].

Załóżmy, że według oceny eksperta zmienne modelu (czynniki ryzyka) przyjmują aktualnie następujące wartości rozmyte: kategoria zagrożeń 3.2, straty materialne 10.320 oraz straty moralne 3. Aby wyznaczyć stopnie przynależności tych wartości do odpowiednich zbiorów rozmytych, należy skorzystać z analitycznej postaci właściwych funkcji przynależności. Zgodnie z tabelą 1. ogólna formuła trapezowej funkcji przynależności ma postać (rys. 8.):

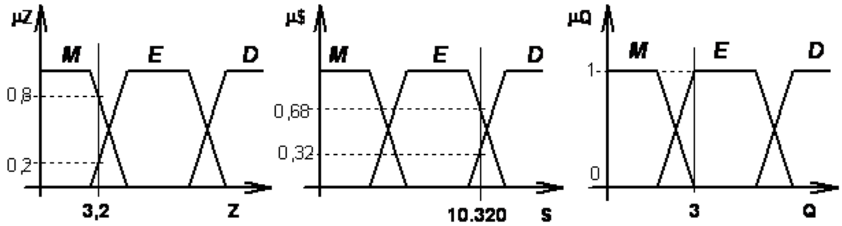

Rys. 8. Przykładowe realizacje funkcji przynależności dla wybranych wartości zmiennych lingwistycznych — czynników ryzyka

Źródło: opracowanie własne.

Na podstawie przeprowadzonych obliczeń dla przykładowych wartości zmiennych wejściowych ZG = 3.2, S = 10.320 i Q = 3 uzyskano następujące stopnie przynależności poszczególnych zmiennych rzeczywistych do zbiorów rozmytych (tabela 2.):

Tabela 2. Struktura zbiorów rozmytych ZG, S$ i SM

Czynniki	**Wartość**	**Zbiory M**	**Zbiory E**	**Zbiory D**
Kategoria zagrożeń	3.2	0.8	0.2	–
Straty materialne	10.320	–	0.68	0.32
Straty moralne	3	0	1	–

Źródło: opracowanie własne.

Dane zawarte w tabeli 2. można interpretować w sposób następujący. Wartości kategoria zagrożeń Z = 3.2 odpowiada przynależność w stopniu 0.2 do zbioru rozmytego E „niespodziewane" oraz w stopniu 0.8 do zbioru rozmytego M „normalne". Analogiczną interpretację mają straty materialne (S). Natomiast straty sanitarne (Q) kwalifikowane są jako pełna przynależność do zbioru „nieakceptowane", a brak przynależności do zbioru „akceptowane" [4].

Do oceny ryzyka (RK) wykorzystamy schemat wnioskowania oparty na regułach określonych przez eksperta, którego wiedza merytoryczna została implementowana np. przez inżyniera wiedzy w postaci zestawu reguł logicznych opartych na modelu Mamdaniego [14]. Symboliczny zapis pełnego zestawu reguł wnioskowania dla trzech zmiennych lingwistycznych przyjmujących (2 x 3 = 6) i (1 x 1 = 1) wartości lingwistyczne przedstawia tabela 3.

Tabela 3. Teoretyczny zestaw reguł eksperckich przy wyznaczaniu przykładowego ryzyka wieloczynnikowego

Nr reguły	**Kategoria zagrożenia**	**Straty materialne**	**Straty moralne**
1	ZG = M	S$ = M	SM = E
2*	ZG = M	S$ = E	SM = E
3*	ZG = M	S$ = D	SM = E
4	ZG = E	S$ = M	SM = E
5*	ZG = E	S$ = E	SM = E
6*	ZG = E	S$ = D	SM = E
7	ZG = D	S$ = M	SM = E
8	ZG = D	S$ = E	SM = E
9	ZG = D	S$ = D	SM = E

Źródło: opracowanie własne.

Aby otrzymać stopnie przynależności poszczególnych czynników ryzyka — zagrożenia (ZG), straty materialne (S$) i starty moralne (SM) — do zbiorów rozmytych reprezentujących wartości zmiennych lingwistycznych potrzebna jest znajomość tylko czterech reguł spełniających warunek prawdziwości przesłanek, tzn. zgodności z przyjętymi założeniami:

R2. IF (ZG IS M) AND (S$ IS E) AND (SM IS E) THEN (RK IS E)

R3. IF (ZG IS M) AND (S$ IS D) AND (SM IS E) THEN (RK IS E)

R5. IF (ZG IS E) AND (S$ IS E) AND (SM IS E) THEN (RK IS (D)

R6. IF (ZG IS E) AND (S$ IS D) AND (SM IS E) THEN (RK IS (D)

Zgodnie z zarysowanym we wstępie schematem wnioskowania rozmytego, na podstawie powyższych reguł wykorzystamy operator typu Max-Min [18]. W tym celu ustalamy minimum ze stopni przynależności poszczególnych przesłanek każdej reguły:

$$0{,}8/M \wedge 0{,}68/E \wedge 1/E = 0{,}68/E \qquad \text{(P1)}$$

$$0{,}8/M \wedge 0{,}32/D \wedge 1/E = 0{,}32/E \qquad \text{(P2)}$$

$$0{,}2/E \wedge 0{,}68/E \wedge 1/E = 0{,}2/D \qquad \text{(P3)}$$

$$0{,}2/E \wedge 0{,}32/D \wedge 1/E = 0{,}2/D \qquad \text{(P4)}$$

Wartości zmiennych lingwistycznych lewej strony równań (P1) — (P4) dotyczą przesłanek, czyli czynników ryzyka. Prawa strona tych równań zawiera wynikowe zbiory rozmyte dotyczące badanego ryzyka. W dalszej kolejności stosujemy do układu równań (P1) — (P4) operator MAX, celem uzyskania rozmytego wyniku wnioskowania:

$$0{,}8/E \vee 0{,}32/E \vee 0{,}2/D \vee 0{,}2/D = 0{,}68/E \vee 0{,}2/D. \qquad \text{(P5)}$$

Lewa strona równania (P2) daje mam szukane rozwiązanie, czyli wartość lingwistyczną ryzyka w postaci dwóch zbiorów rozmytych, które będziemy interpretować następująco. Wartość wygenerowanego ryzyka należy w stopniu 0.8 do zbioru rozmytego E (ryzyko średnie) i w stopniu 0.2 do zbioru rozmytego D (ryzyko duże).

Dla celów praktycznych taka informacja jest mało przydatna i dlatego będzie podlegać procesowi defuzyfikacji (ostrzenia) celem otrzymania liczbowej wartości syntetycznej. Operację defuzyfikacji wykonuje się za pomocą ogólnie dostępnych metod. Jedną z najbardziej popularnych jest metoda środka ciężkości, którą zastosujemy poniżej. Wybór konkretnej metody defuzyfikacji zależy od rozwiązywanego problemu. W ogólności powinna ona odznaczać się prostotą obliczeniową, jednoznacznością i czułością, co oznacza, że nawet niewielkim zmianom w przesłankach poszczególnych reguł wnioskowania powinna odpowiadać proporcjonalna zmiana wyniku procesu defuzyfikacji. Zaproponowana metoda środka ciężkości spełnia większość postulowanych warunków, ale w praktyce należy do uciążliwych pod względem obliczeniowym [1, 14].

Stosując uproszczoną metodę środka ciężkości CoG (12), ostrą wartość ryzyka wieloczynnikowego RK będziemy określać na podstawie uprzednio wyznaczonych środków ciężkości dla zbiorów rozmytych — „ryzyko średnie" (0,68/E) i „ryzyko wysokie" (0,2/D), posługując się następującym wyrażeniem:

$$\mathrm{RK} = \frac{0{,}68\ \times \Omega_1\{0{,}3; 0{,}4; 0{,}7; 0{,}8\} + 0{,}2 \times \Omega_2\{0{,}7; 0{,}8; 1; 1\}}{0{,}68 + 0{,}2} = 0{,}624,$$

gdzie:

Ω_1, Ω_2 — przestrzenie topologiczne, w tym przypadku czterowymiarowe, dla których została wyznaczona metryka zbioru [16].

Z wykresu na rysunku 7. odczytujemy, że otrzymana w wyniku defuzyfikacji ostra wartość ryzyka RK = 0,624 odpowiada pełnej przynależności ryzyka do zbioru E („ryzyko średnie").

Do zobrazowania procesu wnioskowania w oparciu o regułę Mamdaniego i bazę wiedzy eksperta wykorzystano tylko trzy zmienne (czynniki ryzyka), którym zgodnie z tabelą 1. przypisano wartości lingwistyczne i wartości statystyczne. Dysponując takim modelem dla zadanych zbiorów rozmytych (zagrożenia, straty materialne i straty moralne), możemy zmieniać aktualne eksperckie oceny czynników ryzyka i prowadzić badania, np. pod kątem ich wpływu na poziom funkcji ryzyka. Można również zmienić strukturę dotychczasowych zbiorów rozmytych — tabela 2. i badać zachowanie się funkcji ryzyka (15) w nowych przedziałach zmienności tych zbiorów, dla innych formuł zadanych funkcji przynależności. Odpowiednio oprogramowany model może być także wykorzystany do badań zupełnie innych funkcji ryzyka zdefiniowanych za pomocą większej liczby czynników albo też przy bardziej rozbudowanym repertuarze zbiorów rozmytych dla każdego z tych czynników [17]. Niestety, zwiększanie wymiarowości modelu ze względu na lawinowo rosnące trudności obliczeniowe wymaga praktycznego zastosowania technologii komputerowej.

UWAGI I WNIOSKI KOŃCOWE

Zaprezentowany w pracy przykład zastosowania sterowników Mamdaniego do wyznaczania ryzyka wieloczynnikowego z udziałem eksperckiej bazy wiedzy potwierdza pełną ich przydatność, oprócz tradycyjnie uznawanej techniki i technologii także w dziedzinie nauk „miękkich”, np. społecznych. Prezentowane w światowej literaturze inne niż techniczne zastosowania sterowników Mamdaniego pokazują coraz to nowe obszary aplikacyjne rozmytej teorii *Fuzzy*.

Ryzyko wieloczynnikowe wyznaczone za pomocą modeli Mamdaniego uwzględnia heurystyczną bazę wiedzy zapisaną w postaci logicznych reguł wnioskowania typu *Modus Ponens*. Operowanie lingwistyczną i rozmytą bazą wiedzy jest najbardziej właściwym procesem intelektualnej działalności eksperta. Tylko sformalizowane modele Mamdaniego pozwalają na stosunkowo prostą i efektywną jej konstrukcję i niemal intuicyjne wykorzystanie.

Ze względu na konieczność wykonywania dość pracochłonnych obliczeń matematycznych i związane z tym przekleństwo wielowymiarowości (*Curse of Dimensionality)* praktyczne posługiwanie się modelami Mamdaniego wymaga skutecznego wspomagania ze strony współczesnej technologii informatycznej. Postulat ten w pełnym zakresie spełnia między innymi standardowy pakiet *Fuzzy Logic Toolbox* znajdujący się w inżynierskim systemie MatLab [8], pozwalający na efektywne wykorzystanie wszystkich potencjalnych możliwości teorii i systemów *Fuzzy*.

Jak wynika z literatury [1, 9, 14, 19], specyfikacja rzeczywistych i perspektywicznych kierunków zastosowań systemów rozmytych *Fuzzy* zdaje się nie mieć końca. Zastosowania *stricte* techniczne obejmują rozmaite układy sterowania, w tym sterowanie hamulcami samochodów (ABS), bojlerem wodnym, blokami energetycznymi, urządzeniami chłodniczymi, piecami hutniczymi, obróbką metali, suwnicą (dźwigiem), stacją pomp, ładowaniem akumulatorów, urządzeniami spawalniczymi i wiele innych. W obszarze zastosowań medycznych zaawansowane modele „inteligentnych” sterowników wykorzystywane są np. do sterowania rozrusznikiem serca, ciśnieniem krwi, diagnostyką nowotworową, terapią diabatyczną, poziomem cukru we krwi, diagnostyką chorób serca itp. Inne ciekawe ich zastosowania to np. przetwarzanie obrazów, rozpoznawanie słów, podejmowanie decyzji czy sterowanie ruchem drogowym [18]. Szczególnie duże nadzieje stwarza teoria zbiorów rozmytych i będące jej narzędziową aplikacją modele Mamdaniego w obszarze „miękkich” nauk jakościowych, takich jak kognitywistyka i tzw. miękka sztuczna inteligencja (*Soft Artificial Intelligence*).

BIBLIOGRAFIA

[1] Driakov D., Hellendoorn H., Reinfrank M., *Wprowadzenie do sterowania rozmytego*, WNT, Warszawa 1996.

[2] Ficoń K., *Międzynarodowe standardy zarządzania ryzykiem*, „Bellona", 2013, nr 2.

[3] Ficoń K., *Identyfikacja i zwalczanie zagrożeń i czynników ryzyka w projektach innowacyjnych*, „Zeszyty Naukowe AMW", 2008, nr 175B.

[4] Ficoń K., *Inżynieria zarządzania kryzysowego. Podejście systemowe*, BEL Studio, Warszawa 2007.

[5] Ficoń K., *Sztuczna inteligencja. Nie tylko dla humanistów*, BEL Studio, Warszawa 2012.

[6] Ficoń K., *Wybrane jakościowe metody szacowania ryzyka zawodowego według standardów branżowych*, Forum Bezpieczeństwa, t. 1, AMW, Gdynia 2012.

[7] Flasiński M., *Wstęp do sztucznej inteligencji*, PWN, Warszawa 2011.

[8] Gulley N., Rogerjang J. S., *Fuzzy Logic Toolbox*, The Math Works, 1995.

[9] Kacprzak J., *Wieloetapowe sterowanie rozmyte*, WNT, Warszawa 2001.

[10] Kaczmarek T. T., *Ryzyko i zarządzanie ryzykiem. Ujęcie interdyscyplinarne*, Difin, Warszawa 2005.

[11] Kisielewicz A., *Sztuczna inteligencja i logika. Posumowanie przedsięwzięcia naukowego*, WNT, Warszawa 2011.

[12] Mamdani E. H., *Advances in the linguistic synthesis of fuzzy controllers*, 'International Journal of Man-Machine Studies', 1977 (8).

[13] Mamdani E. H., *Applications of fuzzy algorithms for the control of a simple dynamic plant*, Proccedings of IEE, 1976 (121).

[14] Piegat A., *Modelowanie i sterowanie rozmyte*, EXIT, Warszawa 2003.

[15] Polska Norma PN-EN-18002: 2000, *Systemy zarządzania bezpieczeństwem i higieną pracy. Ogólne wytyczne do oceny ryzyka zawodowego.*

[16] Rasiowa H., *Wstęp do matematyki współczesnej*, BM, t. 30, PWN, Warszawa 1979.

[17] Romanowska-Słomka J., Słomka A., *Zarządzanie ryzykiem zawodowym*, Tarbonus, Tarnobrzeg 2001.

[18] Rutkowska D., Piliński M., Rutkowski L., *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*, PWN, Warszawa 1997.

[19] Rutkowski L., *Metody i techniki sztucznej inteligencji*, PWN, Warszawa 2006.

[20] Takagi T., Sugeno M., *Derivation of fuzzy control rules from human operator's control actions*, Proccedings of IFAC, 1983.

[21] Zadeh L. A., *Fuzzy algorithm*, 'Information and Control', 1968 (12)

[22] Zadeh L. A., *Fuzzy logic and approximate reasoning*, 'Synthese', 1975 (30).

[23] Zadeh L. A., *Fuzzy sets*, 'Information and Control', 1965 (8).

APPLICATION OF MAMDANI FUZZY CONTROLLERS IN SPECIFICATION OF MULTIFACTORIAL RISK

ABSTRACT

The article reveals the concept of using of L. A. Zadeh fuzzy sets theory in order to determine the multispectral risk taking into consideration the linguistic knowledge base. The target fuzzy model of such system was prepared following generalized main standard of the fuzzy controller developed by E. H. Mamdani. The introduction of following paper contains the broad outline of Zadeh fuzzy set theory as well as application idea of Mamdani fuzzy controllers. The following part introduces an example of the fuzzy system, which can be used to determine the multispectral risk basing on rules of fuzzy logic and linguistic functions. This pioneer work is an attempt to use formal apparatus of the fuzzy sets theory to determine the multispectral risk taking into consideration labor safety standards.

Keywords:

membership function, fuzzification, defuzzification, inference, fuzzy logic, risk, fuzzy controller, the linguistic value, fuzzy set, linguistic variable.