ZESZYTY NAUKOWE POLITECHNIKI ŚLĄSKIEJ 1989

Seria: AUTOMATYKA z. 93 Nr kol. 969

Tomasz RAWLIK

KLASYFIKACJA SYTUACJI METODAMI ROZMYTYMI

Streszczenie. W pracy przedstawiono proponowaną metodę rozpoznawania obrazów na podstawie wartości logicznej struktury lingwistycznej "zbiór predykatów A spełnia warunki klasy i". Zaproponowano sformalizowane określenie wartości pewnych modyfikatorów ilościowych przedstawianych w nowo określonej formie zbioru typu FT. Metodę zilustrowano przykładem diagnostyki dwustopniowego wzmacniacza tranzystorowego, z wykorzystaniem operacji max-min.

Wstęp

Rozpoznawanie obrazów, czyli klasyfikacja, stanowi pierwszy i podstawowy etap każdej działalności. Rozpoczyna się ono od rozpoznania występującej sytuacji, a następnie po jej sklasyfikowaniu podejmowane jest działanie odpowiednie dla danej klasy zdarzeń. Matematycznie sformalizowana teoria decyzji, funkcji klasyfikujących czy też zagadnienia minimalizacji funkcjonałów określonych na przestrzeniach stanów pozwalają na rozwiązywanie wielu problemów występujących w praktyce i są szeroko opisane w literaturze [1], [2], [8]. Istnieje jednakże duża liczba przypadków, w których metody te zawodzą, gdyż nawet szybkość obliczeń i pojemność pamięci dużych maszyn cyfrowych nie gwarantuje zakończenia przetwarzania odpowiedniej ilości informacji w rozsądnym czasie. Pewnym obiecującym narzędziem do rozwiązywania części tych zagadnień są zbiory rozmyte [4]. Wprowadzone przez prof. Zadeha w 1965 r., opracowane następnie przez wielu autorów, pozwalają na pewne sformalizowanie procedur przetwarzania nieprecyzyjnej, rozmytej informacji, tak charakterystycznej dla wielu problemów rozwiązywanych przez człowieka. Artykuł ten poświęcony jest próbie przedstawienia rozpoznawania obrazów jako klasyfikację prawdziwości zdania: "występujący zespół cech spełnia zbiór cech klasy i". Podejście takie pozwala po przeanalizowaniu prawdziwości tego zdania dla wszystkich klas na odpowiednią klasyfikację danej sytuacji na podstawie dowolnych, różnorodnych kryteriów. Alternatywną metodą opartą na zbiorach rozmytych jest rozpoznawanie obrazów poprzez rozmyte relacje tworzone na podstawie zbioru reguł typu $A \Longrightarrow B$ (szczegóły w [4], [3], [9]). Prezentowana w artykule metoda w porównaniu z powyższą charakteryzuje się znacznym zmniejszeniem liczby obliczeń oraz wymaga mniejszego obszaru pamięci w porównywalnych przypadkach.

W pracy używane są standardowe formy zapisu:
zbiór rozmyty A określony na przestrzeni X, $A \subset X$, poprzez funkcję przynależności μ_A: $X \longrightarrow (0,1)$.
Dla dyskretnych $X = [x_1, \ldots, x_N]$, A zapisywany jest w formie wektorowej

$$A = [\mu_A(x_1), \ldots, \mu_A(x_N)]$$

Jako szczególny przypadek zbioru rozmytego rozpiętego na przestrzeni $X = [x_1, \ldots, x_N]$ proponuję wprowadzenie zbioru typu $F\pi$ (rys. 1) oznaczanego: $A_{F\pi} = [x_A, x_B, x_C, x_D]$, dla którego zachodzi:

$$\mu_A(x) = \begin{cases} 0 & x < x_A \\ \dfrac{2(x-x_A)^2}{(x_B-x_A)^2} & x \in \langle x_A, \dfrac{x_A+x_B}{2} \\ 1 - \mu(x_A+x_B-x) & x \in \langle \dfrac{x_A+x_B}{2}, x_B) \\ 1 & x \in \langle x_B, x_C) \\ 1 - \dfrac{2(x-x_C)^2}{(x_C-x_D)^2} & x \in \langle x_C, \dfrac{x_X+x_D}{2} \\ 1 - \mu(x_C+x_D-x) & x \in \langle \dfrac{x_C+x_D}{2}, x_D) \\ 0 & x \geq x_D \end{cases}$$

Przyjęto następujące oznaczenia rachunku zbiorów (p. [5], [6]):

- iloczyn zbiorów, określony dla A, $B \subset X$ (oznaczany $A \cap B$) na podstawie funkcji przynależności $\mu_A(x)$, $\mu_B(x)$, jako:

$$\bigwedge_{x \in X} \quad \mu_{A \cap B}(x) = \mu_A(x) \odot \mu_B(x)$$

gdzie:

$\odot$ oznacza t-normę [5], [7], przykładowo
$a \odot b = a \cdot b$,
$a \odot b = \min(a,b)$

- suma zbiorów $A,B \subset X$ (oznaczana $A \cup B$) określana jako:

$$\bigwedge_{x \in X} \mu_{A \cup B}(x) = \mu_A(x) \oplus \mu_B(x)$$

gdzie:

$\oplus$ oznacza t-konormę (p. [7],[5]).

Przykładami t-konorm, używanymi najczęściej w zagadnieniach praktycznych, mogą być (w uporządkowaniu rosnącym):

$$\max(a,b) \leq a+b-ab \leq \min(1,\ a+b)$$

- dopełnienie zbioru A, A^c, którego funkcja przynależności obliczana może być jako (inne przykłady dopełnień p. [7]):

$$\bigwedge_{x \in X} \mu_{A^c}(x) = 1 - \mu_A(x)$$

- implikacja (II rodzaju powiązana z określoną t-normą):

$$\bigwedge_{x \in X} \mu_{A \to B}(x) = \sup\left\{s \in \langle 0,1\rangle;\ \mu_A(x) \odot s \leq \mu_B(x)\right\}$$

Łatwo sprawdzić (p. [7]), że tak określona implikacja spełnia postawiony przez Zadeha warunek prawdziwości:

implikacja jest prawdziwa $\iff \bigwedge_{x \in X} \mu_A(x) \leq \mu_B(x)$

Dodatkowo w pracy używane jest pojęcie mocy zbioru rozmytego wyprowadzone w analogii do mocy zbiorów skończonych, jako

$$\mathrm{Card}(A) = \sum_X \mu_A(x)$$

<u>Lingwistyczna interpretacja przestrzeni zdarzeń</u>

Zakładamy, że każde interesujące nas zdarzenie $\mathcal{A} \subset U$ (U-universum) możemy opisać za pomocą skończonego zespołu cech oraz że istnieje taki skończony podzbiór cech (predykatów), za pomocą którego możemy rozróżnić dowolne dwie różne sytuacje. Zbiór ten oznaczamy $P = \{p_j\}$, $j = 2,\dots,M$, tworzy on podprzestrzeń dyskretną, na której określane są zdarzenia oraz klasy zdarzeń w formie zbiorów rozmytych.

$$\bigwedge_{\mathcal{A} \subset U} \bigvee_{\mathcal{P} \mid \mathrm{Card}(\mathcal{P}) \leq \omega} \mathcal{A} \hat{=} A = \left\{(p_i, \mu_A(p_i)) \mid p_i \in \mathcal{P}\right\}$$

oraz:

$$\bigvee_{\substack{P'=\{p_j\}\subset\mathcal{P}\\ \mathrm{Card}(P')<\omega}} \bigwedge_{l,k\in N} \mathcal{A}_l \neq \mathcal{A}_k \Longrightarrow A_l \neq A_k$$

Niech $Z = \{Z_i\}$ zbiór klas obiektów (sytuacji) scharakteryzowany poprzez zbiory rozmyte Z_i określone na przestrzeni predykatów P funkcją przynależności $\mu_{Zi}(p_j)$ zapisane w postaci wektorowej:

$$Z_i = \left[\mu_{Zi}(p_1),\ldots,\mu_{Zi}(p_M)\right]$$

Intepretacją zbioru rozmytego Z_i jest zbiór współczynników określających istotność spełnienia danego predykatu do zakwalifikowania sytuacji do klasy Z_i. Spośród wszystkich klas wyróżnimy klasę $Z_N = [5,\ldots,.5])$ odpowiadającą całej przestrzeni P), do której klasyfikowane są sytuacje nie dające przypisać się do żadnej z pozostałych z odpowiednim poziomem wiarygodności.

Zdarzenie występujące w rzeczywistości określimy jako zbiór rozmyty rozpięty na przestrzeni P, $A \subset P$. Funkcję przynależności tego zbioru tworzą liczby będące stopniem prawdziwości zdania: "w sytuacji A, p_j jest spełniony", czyli:

$$\mu_A(p_j) = \mu_T(\text{"wA jest } p_j\text{"})$$

gdzie:

$$\mu_T(x) \in \langle 0,1\rangle$$

Problem klasyfikacji sytuacji A do odpowiedniej klasy zdarzeń sprowadza się do obliczenia dla każdej klasy Z_i wartości logicznej:

$$\mu_T(\text{"A spełnia Q kryteriów klasy } Z_i\text{"})$$

a następnie określenia tej klasy Z_{i0}, dla której:

$$\bigwedge_{\substack{i\neq i0\\ i\in N}} \mu_T(\text{"AQ}Z_{i0}\text{"}) \geq \mu_T(\text{"AQ}Z_i\text{"})$$

czyli

$$Z_{i0} = \begin{cases} \arg\max\limits_{i\in N} \mu_T(\text{"AQ}Z_i\text{"}) & \\ Z_N & \text{gdy} \quad \bigwedge\limits_{i\in N} \mu_T(\text{"AQ}Z_i\text{"}) \leq \alpha \end{cases}$$

gdzie: α - współczynnik wiarygodności klasyfikacji $\alpha \in \langle 0,1\rangle$.

W postawionym zagadnieniu występuje lingwistyczny kwantyfikator ilościowy Q, określający, jaka część predykatów musi być spełniona, aby można było przeprowadzić prawdziwą klasyfikację. Kwantyfikator ilościowy przedstawiony jest jako zbiór rozmyty na przedziale (0,1), opis działania kwantyfikatorów przy różnych metodach obliczania wartości logicznej twierdzeń przedstawiony będzie w dalszym ciągu pracy, przykładami ilościowych kwantyfikatorów lingwistycznych mogą być:

$$\text{"większość"}_{F\pi} = [.3,.8,1,1]$$
$$\text{"wszystkie"}_{F\pi} = [1,1,1,1]$$
$$\text{"wszystkie a"}_{F\pi} = [.7a,a,1,1]$$

oraz pochodne będące złożeniem prostych kwantyfikatorów ilościowych z modyfikatorami (p. [4]) np.:

$$\mu_{\text{"prawie wszystkie"}}(x) = \mu^{1/2}_{\text{"wszystkie"}}(x)$$

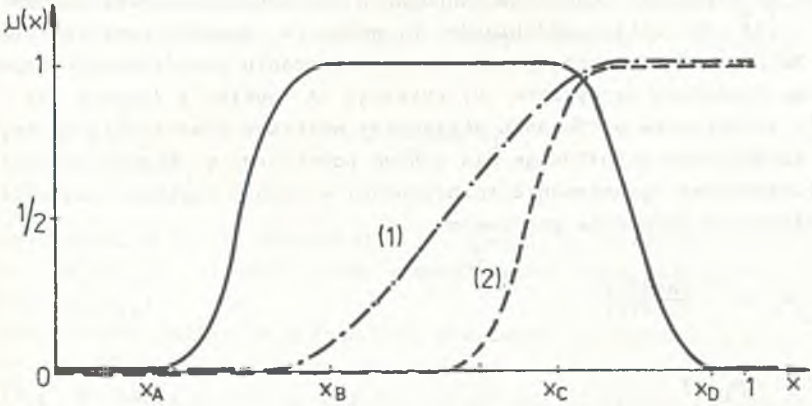

Rys. 1. Reprezentacja graficzna zbioru rozmytego typu F $A_{F\pi} = [x_A, x_B, x_C, x_D]$ oraz kwantyfikatorów ilościowych "większość" (1) oraz "wszystkie 0.8" (2)
Fig. 1. Graphic representation of fuzzy set of F type $A_{F\pi} = [x_A, x_B, x_C, x_D]$ and quantity quantificators "majority" (1) and "all 0.8" (2)

Metody oceny logicznej zdań

Przy opracowaniu metody posłużono się dwoma alternatywnymi metodami obliczania wartości logicznej konstrukcji lingwistycznych. Wprowadzona przez Zadeha metodą algebraiczną oraz metodą analizy podzbiorów przestrzeni P zaproponowaną i opracowaną przez Yagera i Kacprzyka [7], [10].

I - metoda algebraiczna

Niech sytuacja A określona będzie jako rozmyty zbiór na P funkcję przynależności $\mu_A(p_j) = \mu_T$("w A p_j jest spełniony"). Obliczamy wartość logiczną "A spełnia QZ_i" jako:

$$\mu_T(\text{"}AQZ_i\text{"}) = \mu_Q(x_i)$$

gdzie:

$$x_i = \frac{\mathrm{Card}(A \cap Z_i)}{\mathrm{Card}\ Z_i} = \frac{\sum_j \mu_A(p_j) \odot \mu_{Z_i}(p_j)}{\sum_j \mu_{Z_i}(p_j)}$$

$\odot$, dowolna t-norma odzwierciedlająca obszar przecięcia zbiorów A i Z_i.

II - metoda podstawiania (analizy podzbiorów P)

Przyjmując wszystkie pozostałe oznaczenia jak poprzednio, wprowadźmy zbiór $V = \{v\}$ wszystkich podzbiorów P, gdzie v dowolny podzbiór predykatów. Metoda podstawiania opiera się na obliczeniu prawdziwości zdania: "dla danego podzbioru predykatów v, sytuacja A wynika z (należy do) klasy Z_i", a następnie porównaniu otrzymanej wartości z wartością kwantyfikatora ilościowego określonego dla danego podzbioru v. W celu ujednolicenia obliczeń oraz ograniczenia rozbieżności w ocenie wartości kwantyfikatorów ilościowych proponuję przyjęcie:

$$a = \mu_c(v) = \frac{\mathrm{Card}(V)}{\mathrm{Card}(P)}$$

$$\mu_Q(v) = \mu_Q(a)$$

W efekcie wartość logiczną rozpatrywanej konstrukcji zdaniowej otrzymujemy jako złożenie (sumę) elementarnych implikacji po całym zbiorze V. Autorzy metody precyzują tę wartość jako maksimum po V ze zbioru wartości logicznej implikacji weryfikowanej kwantyfikatorem ilościowym. W ścisłym ujęciu, kolejne obliczenia przedstawiają się następująco:

$$\mu_T(v/A) = \bigvee^{\oplus}_{j:p_j \in v} \mu_A(p_j)$$

$$\mu_T(\text{"}AQZ_i\text{"}) = \bigvee^{\oplus}_{v \in V} (\mu_Q(v) \odot (\bigvee^{\odot}_{j:p_j \in v} (\mu_{Z_i}(p_j) \Longrightarrow \mu_A(p_j))))$$

gdzie $\odot$ dowolna t-norma, $\Longrightarrow$ implikacja dowolnie określona, w szczególnym przypadku można stosować implikację generowaną przez tę samą, co poprzednio t-normę. W opracowaniu źródłowym (p. [7]) w miejsce ogólnie określonej t-konormy, $\oplus$, jest używana operacja maximum, wpływ zmiany tej operacji nie został w tej pracy przebadany.

W ocenie prawdziwości badanego zdania obie te metody mogą być używane zamiennie, chociaż nie we wszystkich przypadkach dają te same rezultaty (jest to oczywiście konsekwencją rozmytej wartości spełnienia poszczególnych predykatów). W obliczeniach za wyjątkiem operacji maximum precyzowanej przez autorów metody nie występują określone typy t-norm i-konorm, pozwala to na dostosowanie formy obliczeń do konkretnych celów.

Następnym etapem rozpoznawania obrazów jest proces wyboru klasy, do której należy przypisać zaobserwowaną sytuację A. Wybór ten może być przeprowadzany według różnych kryteriów, najbardziej oczywiste omówione będą w następnym podrozdziale.

Klasyfikacja zgodnie z wartością logiczną zdania

Podstawową metodą określania klasy przynależności zdarzeń jest metoda maksymalnej wiarygodności. Posługując się aparatem wprowadzonym uprzednio możemy zapisać:

$$A \in Z_{i0}\Big|_{\mu_T(Z_{i0})} \Longleftrightarrow Z_{i0} = \arg\max_{i \in N} \mu_T(Z_i)$$

Co odczytujemy w formie zdaniowej: "A, $L[\mu_T(Z_i)]$ należy do klasy Z_{i0}" gdzie $L[\mu_T(Z_{i0})]$ - lingwistyczny kwantyfikator odpowiadający wartości logicznej $\mu_T(Z_{i0})$.

Na podkreślenie zasługuje jednak fakt możliwości występowania sytuacji, której prawidłowa klasyfikacja nie jest możliwa przy określonym zbiorze $Z = \{Z_i\}$. W części pierwszej przedstawiono taki przypadek za pomocą parametru α, określającego minimalny stopień wiarygodności klasyfikacji. Zgodnie z poprzednimi zapisami:

$$A \in Z_{i0}\Big|_{\mu_T(Z_{i0})} \Longleftrightarrow Z_{io} = \begin{cases} \arg\max_{i \in N} \mu_T(Z_i) \\ Z_N \quad \text{gdy} \quad \bigwedge_{i \in N} \mu_T(Z_i) \leq \alpha \end{cases}$$

Przedstawione określenie nie zawiera jednak informacji o "rzetelności" klasyfikacji. "Rzetelność" określana jest parametrem Q. Po wprowadzeniu Q jako dodatkowego parametru, rozwiązanie zagadnienia otrzymujemy w postaci stwierdzenia:

"A, $L[\mu_T(Z_{i0})]$ należy do klasy Z_{i0}, przy przyjętej $L_w[Q]$", gdzie $L_w[Q]$ - lingwistyczny kwantyfikator określony na zbiorach rozmytych;

lub w sposób bardziej naturalny:

"A, $L[\mu_T(Z_{i0})]$ spełnia Q parametrów Z_{i0}"

Pełny, sformalizowany zapis rozwiązania przedstawia się następująco:

$$A \in Z_{i0}\Big|^{Q}_{\mu_T(Z_{i0})} \Longleftrightarrow Z_{i0} = \begin{cases} \arg\max\limits_{i\in N} \mu_{TQ}(Z_i) \\ Z_N \quad \text{gdy} \quad \bigwedge\limits_{i\in N} \mu_T(Z_i) \leqslant \alpha \end{cases}$$

Ponieważ w przypadku ogólnym $Z_{i0}\Big|^{Q_1} \neq Z_{i0}\Big|^{Q_2}$, wprowadzenie określenia stopnia rzetelności jest konieczne przy rozpatrywaniu klasyfikacji zdarzeń.

Inną pochodną metodą jest poszukiwanie rozwiązania w całym obszarze kwantyfikatorów jakościowych Q. Celem uzewnętrznienia malejącego wpływu wartości $\mu_T(Z_{i0})$ przy Q dążącym do $Q_{F\pi} = [0,0,0,0]$ należy wprowadzić współczynniki wagowe $\gamma_n(Q_n) \leqslant 1$ i wtedy:

$$\mu_T(Z_i) = \bigvee_n^{\oplus} (\gamma_n * \mu_{TQ_n}(Z_i))$$

Klasyfikacja końcowa przeprowadzona jest metodą maksymalnego poziomu wiarygodności (oczywiście bez uwzględnienia "rzetelności"). Inne metody klasyfikacji końcowej wyprowadzono poprzez analogię do klasycznego podejścia beyesowskiego. Wykorzystano współczynnik (β_i) określający częstość występowania lub rozmytą dominację (istotność) klasy. Wartości tych współczynników określane są a priori dla danej klasy na podstawie informacji dodatkowych lub też w przypadku tworzenia uczących się algorytmów klasyfikujących, obliczane są na bieżąco. Wartość ta ustalana jest wtedy bezpośrednio na podstawie częstości występowania przypadków grupowanych w określonej klasie i tworzących podstawę do obliczania opisów wzorów klas.

Przed dokonaniem ostatecznego wyboru Z_{i0} wartość $\mu_T(Z_i)$ poddawana jest modyfikacji poprzez β_i. W podstawowych rozwiązaniach uwzględniono dwa rodzaje oddziaływania:

$$\mu_{Tk}(Z_i) = S^{(1)}(\beta_i) * \mu_T(Z_i) \quad \text{lub} \quad \mu_{Tk}(Z_i) = \mu_T S^{(2)}(\beta_i)(Z_i)$$

gdzie:

$S^{(1)}$ - funkcja niemalejąca $(0;1) \longrightarrow (0;1)$

$S^{(2)}$ - funkcja malejąca $(0;1) \longrightarrow R_+$ $\lim\limits_{\beta_i \to 1} S^{(2)} = 0$

$\lim\limits_{\beta \to} S^{(2)} = \infty$

W wyniku przeprowadzonych modyfikacji otrzymujemy zdanie opisujące przynależność obrazu - sytuacji A do każdej klasy. Zdanie to do bezpośredniej komunikacji człowiek-maszyna formułowane jest następująco:

$$\text{"A, } L\left[\mu_{Tk}(Z_{i0})\right] \text{ reprezentuje klasę } Z_{i0}\text{"}$$

Klasyfikacja końcowa uwzględnia w takim przypadku częstość występowania klas oraz co jest tego bezpośrednią konsekwencją, zwiększa się prawdopodobieństwo prawidłowej klasyfikacji w przypadku dużej rozpiętości tego parametru.

PRZYKŁAD

Przykładem zastosowania przedstawionej metody niech będzie opisana w [2] diagnostyka układu dwustopniowego wzmacniacza tranzystorowego (rys. 2). Obszary przynależności do klas autor [2] uzyskał metodami uczenia, opierając się na funkcji gęstości rozkładu prawdopodobieństwa wektora napięć dla określonej klasy (stanu wzmacniacza).

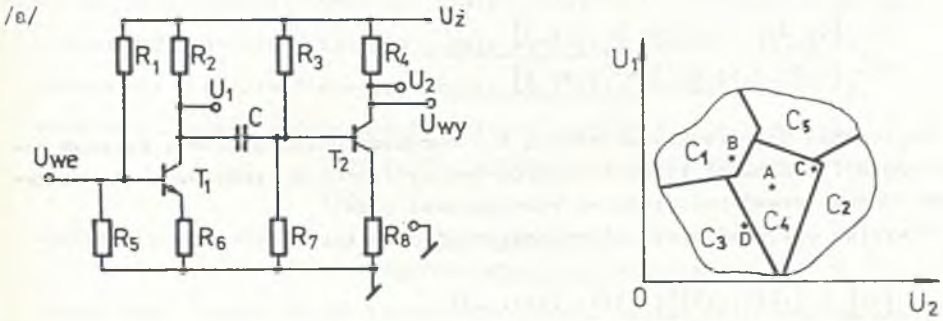

Rys. 2. Badany wzmacniacz tranzystorowy (a). Przestrzeń stanów napięć testowych (b) z wyróżnionymi obszarami klas Z_i (na podst. [2])

Klasy: Z_1 - układ sprawny, Z_2 - kondensator zwarty, Z_3 - T_1 zwarty, Z_4 - T_2 zwarty, Z_5 - żaden z pozostałych stanów

Fig. 2. Investigated transistor amplifier (a). Space of test voltage states (b) with differentiated areas of Z_i classes (basing on [2])

Z_1 - correct system, Z_2 - short circuited condensor, Z_3 - short circuited T_1, Z_4 - short circuited T_2, Z_5 -none of above

Jako przestrzeń P przyjęto zbiór predykatów:

1. U_1 niskie 1N
2. U_1 średnie 1S
3. U_1 wysokie 1W
4. U_2 niskie 2N
5. U_2 średnie 2S
6. U_2 wysokie 2W

oraz odpowiadające poszczególnym klasom zbiory rozmyte Z_i:

	1N	1S	1W	2N	2S	2W	CARD(Z_i)
Z_1	0	0,3	1	1	0	0	2,3
Z_2	1	0,6	0,1	0	0,1	1	2,8
Z_3	1	0,4	0	1	0,5	0	2,9
Z_4	0,6	1	0,1	0,1	1	0,1	2,9
Z_5	0,5	0,5	0,5	0,5	0,5	0,5	3

Celem prezentacji wybranej metody wybrano cztery niezależne zdarzenia oznaczone na rys. 2 punktami A, B, C, D. Funkcje przynależności tych zdarzeń przedstawiają się następująco:

$$A = [0,1;\ 1;\ 0,1;\ 0,1;\ 1;\ 0,1]$$
$$B = [0;\ 0,7;\ 0,7;\ 1;\ 0,3;\ 0]$$
$$C = [0;\ 0,7;\ 0,7;\ 0;\ 0,7;\ 0,7]$$
$$D = [0,8;\ 0,6;\ 0;\ 0,6;\ 0,8;\ 0]$$

Obliczenia przeprowadzono metodą I z uwzględnieniem operacji minimum jako t-normy, dla dwóch lingwistycznych kwantyfikatorów ilościowych z założeniem równego prawdopodobieństwa występowania klas.

W wyniku obliczeń otrzymujemy następujące wektory:

$$[X_A] = [.217;\ .357;\ .379;\ .824;\ .4]$$
$$[X_B] = [.87;\ .286;\ .586;\ .414;\ .45]$$
$$[X_C] = [.435;\ .536;\ .310;\ .552;\ .383]$$
$$[X_D] = [.391;\ .536;\ .793;\ .724;\ .467]$$

Ponieważ w zasadzie zakłada się, że $\mu_Q(x)$ jest funkcją monotoniczną, więc przyjmując do klasyfikacji metodę największej wiarygodności możemy zapisać:

$$A \in Z_4$$
$$B \in Z_1$$
$$C \in Z_4 \vee C \in Z_2$$
$$D \in Z_3 \vee D \in Z_4$$

Aby wskazać stopień wiarygodności przynależności do danej klasy, tzn. jaka część spełnionych parametrów potwierdza hipotezę o przynależności, oblicza

się wartość $\mu_Q(x^i)$. Ponieważ nie jest jednak istotny stopień spełnienia dla obiektów nieklasyfikowanych, to oblicza się tylko: $\mu_Q(x^{i0})$. Wartości te wyznaczono dla dwu lingwistycznych kwantyfikatorów ilościowych:

Q_1 = 'większość' Q_2 = 'prawie wszystkie a' dla a = 0,8

$\mu_T('AQ_1Z_4') = \mu_{Q1}(x_A^4) = \mu_{Q1}(.828) = 1$

$\mu_T('AQ_2Z_4') = \mu_{Q1}(x_A^4) = 1$

$\mu_T('BQ_1Z_1') = 1$

$\mu_T('BQ_2Z_1') = 1$

$\mu_T('CQ_1Z_4') = .508$ $\mu_T('CQ_1Z_2') = .446$

$\mu_T('CQ_2Z_4') = 0$ $\mu_T('CQ_2Z_2') = 0$

$\mu_T('DQ_1Z_3') = 1$ $\mu_T('DQ_1Z_4') = .954$

$\mu_T('DQ_2Z_3') = 1$ $\mu_T('DQ_2Z_4') = .638$

Wynikiem pracy klasyfikatora jest wydruk klasyfikacji końcowej w postaci:

wzmacniacz w stanie A spełnia <u>prawie wszystkie</u> kryteria klasy Z_4

wzmacniacz w stanie B spełnia <u>prawie wszystkie</u> kryteria klasy Z_1

wzmacniacz w stanie C <u>częściowo</u> spełnia <u>większość</u> kryteriów klasy Z_4 oraz <u>prawie częściowo</u> spełnia <u>większość</u> kryteriów klasy Z_2

wzmacniacz w stanie D spełnia <u>prawie wszystkie</u> kryteria klasy Z_3 oraz spełnia <u>większość</u> kryteriów klasy Z_4

Korzystając z wyników obliczeń, metodą algebraiczną obliczono wartość współczynników przynależności $\mu_T'(x,QZ_{io})$ dla Q = "większość" i otrzymano:

$\mu_T'(AQZ_4) = 1$

$\mu_T'(BQZ_1) = 1$

$\mu_T'(CQZ_2) = 0,7$ $\mu_T'(CQZ_4) = 0,62$

$\mu_T'(DQZ_3) = 0,8$ $\mu_T'(DQZ_4) = 0,62$

Ze względu na dużą czasochłonność obliczeń metoda druga predestynowana jest do zastosowań praktycznych tylko w przypadku algorytmów zmniejszających w znacznej mierze liczbę generowanych podzbiorów V. Redukcja liczby odbywa się na zasadzie wykorzystania informacji wynikających z obliczonych uprzednio wartości implikacji.

Zakończenie

W pracy przedstawiono metodę rozpoznawania obrazów, będącą zmodyfikowanym algorytmem badania odległości od wzorca. Modyfikacja polega na rozpoznawaniu nieliniowych cech wzorca i podobieństwach zespołów tak wyróżnianych cech we wzorcu i badanej sytuacji. Miarą odległości przyjętą w algorytmie jest inkluzją zbiorów rozmytych, stanowiących opis klas i sytuacji. Działanie metody zobrazowano przykładem diagnostyki układu dwutranzystorowego z wykorzystaniem przede wszystkim algebraicznej oceny prawdziwości zdań.

LITERATURA

[1] Aizerman M.A. i in.: Rozpoznawanie obrazów. Metoda funkcji potencjalnych. WNT, Warszawa 1976.

[2] Cypkin I.Z.: Podstawy teorii układów uczących się. WNT, Warszawa 1973.

[3] Czogała E.: Fuzzy Set Theory as a Basis for Computer Aided Fault Diagnostics. Sbornik prednašek z II Celostatni Konference sa zahranični učasti. Brno 1979.

[4] Czogała E., Pedrycz W.: Elementy i metody teorii zbiorów rozmytych. Pol. Śl. Gliwice 1983, skrypt uczelniany nr 1160.

[5] Dubois D., Prade H.: Fuzzy Set Theoretic Differences and inclusions... Control and Cybernetics. Vol. 13 3/84 PWN.

[6] Dubois D., Prade H.: Fuzzy Cardinality and the Modeling of Imprecise Quantification. Fuzzy Sets and Systems. 3, 1985. North Holland Pub.

[7] Kacprzyk J., Yager R.R.: Linguistic Quantifiers and Belief Qualification in Fuzzy... Control and Cybernetics Vol. 13, 3, 1984 PWN.

[8] Nilson N.: Maszyny uczące się. PWN, Warszawa 1968.

[9] Straszecka E.: Diagnostyka uszkodzeń aparatury medycznej w oparciu o zbiory rozmyte. Praca dyplomowa, Instytut Elektroniki Pol. Śl., Gliwice 1983.

[10] Yager R.: Fuzzy Decision Making Including Unequal Objectives. Fuzzy Sets and Systems. 1, 1978.

Recenzent: Prof. dr hab. inż. Edmund Lipiński

Wpłynęło do Redakcji 20.04.86 r.

ИСПОЛЬЗОВАНИЕ НЕЧЁТКИХ МНОЖЕСТВ В РАСПОЗНАВАНИИ ОБРАЗОВ

Р е з ю м е

В работе рассматривается новый метод распознавания образов, основан на логической оценке лингвистической структуры "Множество предвестников выполняет требования класса (a)". Используется исчисление лингвистических значений предвестников, основанное на алгебраическом методе, введённым Задехом

и методе Ягера - подставления множеств. В работе введены определённые значения некоторых кванторов в образе нечётких множеств, названные $F\pi$. Полученные свойства иллюстрируются простыми численными примерами диагноза двухтранзисторного усилителя. В окончании работы предложены методы развития использования нечётких множеств в распознавании образов.

A FUZZY APPROACH TO THE PATTERN RECOGNITION

S u m m a r y

The paper deals with a new metod of pattern recognition, based on linguistically quantified structures: "Requirements of class (i) are fulfiled by a set of proposition A".

Calculation of linguistically quantified proposition employed are based on the modified algebraic method proposed by Zadeh and the substitution method presented by Yager. Definite values of certain quantity modifiers are introduced, in a shape of a fuzzy set called $F\pi$.
A simple numerical example of a fault diagnostic of two-stage transistor amplifier forms an illustration of theoretical investigations.
Further steps in developing strategies are pointed in the last part of the paper.