ZESZYTY NAUKOWE POLITECHNIKI ŚLĄSKIEJ 2000
Seria: ELEKTRONIKA z. 12 Nr kol. 1492

Ewa STRASZECKA
Politechnika Śląska, Instytut Elektroniki
Joanna STRASZECKA, Czesław MARCISZ
Wojewódzki Szpital Specjalistyczny nr 1 w Tychach, I Oddział Chorób Wewnętrznych

DEFINIOWANIE CZYNNIKÓW NIEPEWNOŚCI I NIEPRECYZYJNOŚCI NA POTRZEBY WSPOMAGANIA DIAGNOZY MEDYCZNEJ

Streszczenie. W pracy zaproponowano modelowanie czynników niepewności i nieprecyzyjności reguły typu "jeżeli ... to ..." w przypadku jej zastosowania do wspomagania diagnozy medycznej. Omówiono sposoby opisu nieprecyzyjnej przesłanki za pomocą zbioru rozmytego i skali. Zastosowano jednolitą interpretację nieprecyzyjnej przesłanki, niezależnie od sposobu jej określenia (zbiór rozmyty, skala, wartość 0 lub 1). Z pomocą teorii Dempstera-Shafera zdefiniowano pewność diagnozy (konkluzji). Podano przykład wnioskowania we wspomaganiu diagnostyki chorób tarczycy.

DEFINING FACTORS OF UNCETRAINTY AND IMPRECISION FOR MEDICAL DIAGNOSIS SUPPORT

Summary. Uncertainty and imprecision factors modelling for IF-THEN rules used in medical diagnosis support is proposed in the paper. A method of interpretation of an imprecise predicate using fuzzy sets or a scale is described. A unified representation of the imprecise predicate, independently from the manner of its formulation (a fuzzy set, a scale, 0 or 1 values) is suggested. Certainty of a diagnosis (conclusion) is defined on Depster-Shafer theory. An example of reasoning in thyroid gland diagnosis support is provided.

1. Wstęp

Wspomaganie diagnozy medycznej wymaga interpretacji różnorakich czynników niepewności i nieprecyzyjności. Już samo określanie symptomów choroby pociąga za sobą konieczność zdefiniowania pojęć typu „szybka akcja serca" czy „wysokie ciśnienie skurczowe krwi". Pojęcia te mogą być opisane przez zbiory rozmyte. Jednocześnie jednak niektóre objawy formułuje się precyzyjnie, np. płeć lub grupę krwi. Występują również symptomy, które najwygodniej jest charakteryzować za pomocą skali, np. ból. Wszystkie te miary opisują precyzyjność określenia symptomów.

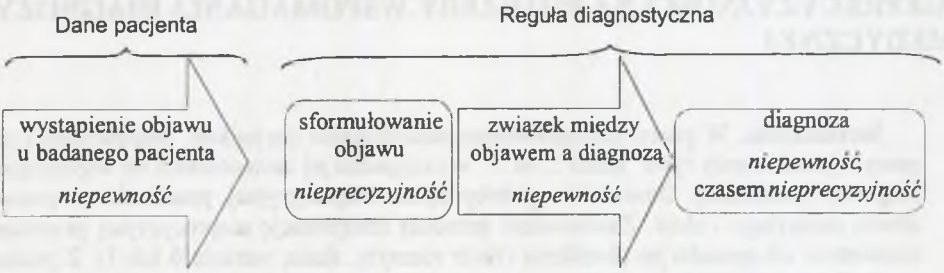

Rys.1. Czynniki niepewności i nieprecyzyjności obecne w procesie wspomagania diagnozy medycznej
Fig.1. Factors of uncertainty and imprecision in medical diagnosis support

Następnie pojawia się problem oceny zależności między obserwowanym objawem a chorobą. Zależność ta w literaturowych schematach diagnostycznych często bywa opisywana za pomocą punktów lub oznaczeń, np. „-", „-/+", „+" [2, 6]. Czasami podaje się wyznaczone na podstawie częstości prawdopodobieństwo wystąpienia objawu pod warunkiem choroby, zaś nadzwyczaj rzadko – prawdopodobieństwo choroby pod warunkiem wystąpienia objawu. „Siłę związku" między symptomem a diagnozą należy niewątpliwie zdefiniować jako stopień pewności, jak to przyjęto w wielu systemach ekspertowych [7, 9].

Diagnoza może być również zdefiniowana nieprecyzyjnie, lecz w zastosowaniach rzadko mamy do czynienia z takim zapisem wiedzy. Trudno bowiem zaakceptować określenie „lekkie zapalenie płuc". Dlatego na ogół większe znaczenie mają miary pozwalające określić pewność diagnozy.

Nieprecyzyjność w sformułowaniu objawu i niepewność związku między objawem a diagnozą są cechami reguły diagnostycznej:

„Jeżeli *symptom* to *diagnoza*".

Stanowią one nieodłączną część bazy wiedzy systemu wspomagania wnioskowania.

W przypadku uruchomienia reguły, a więc podczas sesji wspomagania diagnozy, można natomiast określić niepewność diagnozy. Dla znanych (być może nieprecyzyjnie określonych) objawów obserwowanych u badanego pacjenta uruchamia się (ang. firing) odpowiednie reguły.

O niepewności wystąpienia symptomu należy mówić w przypadku gdy np. pacjent jest zdenerwowany i nie udziela jasnych odpowiedzi, jednak konieczne jest uwzględnienie danych uzyskanych w czasie wywiadu. Tak więc czynniki niepewności i nieprecyzyjności we wspomaganiu diagnozy medycznej można zilustrować jak na rys.1.

W niniejszym artykule zostaną zaproponowane metody definiowania nieprecyzyjności symptomu i niepewności związku między objawem a diagnozą. Zostaną także podane przykłady definicji i zaprezentowana metoda wnioskowania przydatna we wspomaganiu diagnozy medycznej, oparta na teorii Dempstera-Shafera.

2. Określenie nieprecyzyjności objawu w diagnozie medycznej

Zastosowanie zbiorów rozmytych w medycynie jest tyleż celowe, co trudne ze względu na potrzebę uzyskiwania funkcji przynależności od ekspertów [1]. Medycy odnoszą się nieufnie do aparatu matematycznego, ze zrozumiałych względów nie chcą zagłębiać się w teorię zbiorów rozmytych. Pozostaje więc oprzeć się na osiągalnych źródłach informacji, którymi w przypadku wiedzy medycznej są:

1) uśrednione wyniki ankiet opracowanych według modelu: „proszę określić normalne (wysokie, niskie) wartości parametru medycznego",
2) istniejące opracowania statystyczne (podawane w artykułach naukowych),
3) szpitalne bazy danych,
4) algorytmy zawarte w podręcznikach medycznych, zwłaszcza tzw. testy punktowe (przykładami mogą być: test Crooksa w nadczynności tarczycy [6] czy INFARCTEST w określaniu ryzyka zawału serca [14]).

Podstawowym problemem w interpretacji nieprecyzyjności objawu za pomocą zbioru rozmytego jest definiowanie dziedziny, czyli przestrzeni zmienności (ang. „universe of discourse") funkcji przynależności. Przykładami takich kłopotliwych parametrów medycznych mogą być: ból, drżenie rąk, zadyszka wysiłkowa. Wydaje się, że trudno jest uniknąć określania abstrakcyjnej skali w przypadku podobnych symptomów. Jednakże

przyjęcie „sztucznej" dziedziny dla zbioru rozmytego prowadzi zwykle do nienaturalnego, sprzecznego z intuicją zapisu wiedzy. Znacznie łatwiejsze do zaakceptowania byłoby przyjęcie dowolnej skali, która następnie mogłaby być przeliczona na przedział [0,1]. Problemem staje się jednak wtedy jednolita interpretacja symptomów „rozmytych", „skalowanych" i podawanych precyzyjnie przez system wspomagania diagnozy. System ten ma być programem komputerowym, tym lepszym, im bardziej elastycznym, co wyklucza, a przynajmniej ogranicza możliwości indywidualnego rozpatrywania symptomów w mecha-nizmie wnioskowania. W kolejnych punktach niniejszego artykułu proponuje się koncepcję modelowania symptomów „rozmytych", „skalowanych" i „precyzyjnych" oraz metodę jednolitej interpretacji symptomów w procesie wnioskowania.

2.1. Funkcja przynależności jako średnia z opinii ekspertów

Funkcja przynale no ci mo e by okre lona zgodnie z zale no ci :

$$\forall_{x \in S} \; \mu(x) = \frac{1}{n} \sum_{i=1}^{n} D_i(x), \tag{1}$$

gdzie $D_i(x)$ $i=1,...n$ zwykle przyjmują wartości ze zbioru $\{0,1\}$, a więc są tradycyjnie określonymi funkcjami charakterystycznymi zbiorów. Funkcje D_i są definiowane heurystycznie przez ekspertów, a następnie uśrednia się je. Oczywiście, uśrednienie pozwala określić jedynie kilka punktów dla funkcji przynależności, a następnie należy zastosować aproksymację jednym ze standardowych kształtów funkcji przynależności (rys.2).

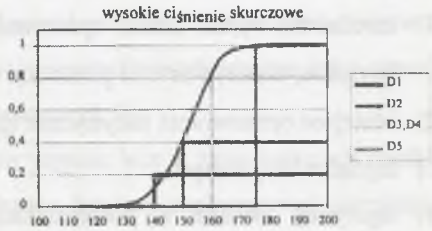

Rys.2. Definiowanie funkcji przynależności na podstawie opinii ekspertów
Fig.2. Defining membership functions on experts' opinions

Uzyskiwanie funkcji przynależności w powyższy sposób czasami jest trudne, ponieważ lekarze nie są skłonni zaznaczyć innych granic dla parametrów medycznych, niż normy przyjęte w literaturze medycznej, mimo iż w codziennej praktyce inaczej interpretują rezultaty "na granicy normy", niż te, które trafiają w jej środek. Z pewnością nie można w ten sposób określić funkcji przynależności dla wyników testów laboratoryjnych.

2.2. Definiowanie funkcji przynależności na podstawie danych statystycznych

Większość testów laboratoryjnych jest często wykonywana, tak więc stosunkowo łatwo można zgromadzić dane o populacji ludzi „zdrowych" (tzn. nie cierpiących na chorobę, którą dany test wykrywa), czyli tzw. grupę kontrolną. Na podstawie rozkładu prawdopodobieństwa wybranego parametru w grupie kontrolnej można zdefiniować funkcje przynależności dla zbioru rozmytego „ normalny", a następnie, poprzez negację, dla zbiorów rozmytych „niski" i „wysoki" (rys.3). Można posłużyć się krzywymi Gaussa lub krzywymi trapezowymi. W przypadku krzywych Gaussa możliwe jest również wyznaczenie funkcji przynależności zbiorów „bardzo niski" i „bardzo wysoki" poprzez operację wyostrzania. Występujące problemy to:

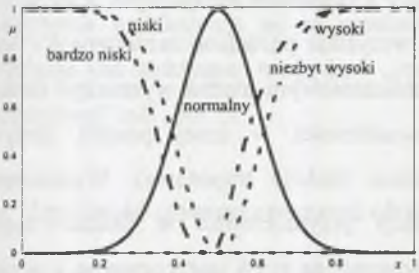

Rys.3. Definiowanie funkcji przynależności na podstawie danych statystycznych
Fig.3. Defining membership functions on statistical data

a) w przypadku rzadkich chorób lub schorzeń, których częstość występowania zależy od regionu (zawodu, płci, wieku itp.) opracowania statystyczne, szczególnie dla grup kontrolnych są zbyt wyrywkowe, aby mogły być przydatne do wspomagania podejmowania decyzji,

b) literaturowe opracowania statystyczne przeważnie odnoszą się do dużych populacji, czasami egzystujących w warunkach znacznie różniących się od badanej grupy pacjentów, stąd ich wyniki nie mogą być w prosty sposób uogólniane.

Systemy powinny wykorzystywać dane pochodzące z populacji, na potrzeby której zostały stworzone, ponieważ im trafniej zdefiniowane są funkcje przynależności, tym efektywniejsze jest wspomaganie diagnozy. Jest to stosunkowo łatwe w przypadku istnienia szpitalnych systemów informacyjnych lub dużych baz danych. Dostatecznie liczne dane mogą być podstawą wyznaczenia krzywych rozkładu normalnego lub funkcji przynależności żądanej postaci za pomocą sieci neuronowych [3]. Jednakże, jak wynika z literatury [8], przynajmniej równie dobrze sprawdzają się metody polegające na aproksymacji histogramów danych. Należy więc przypuszczać, że ewentualne niedostatki spowodowane niewielką licznością danych są rekompensowane poprzez konstruowanie funkcji przynależności dla selektywnie wybranej populacji – tej właśnie, której będzie dotyczyć wspomaganie diagnozy. Wskazuje to kolejną istotną zaletę zastosowania zbiorów rozmytych w medycynie – możliwość

wykorzystania mało licznych danych, które nie mogą być źródłem statystycznie istotnego opisu lub podstawą uczenia sieci neuronowej.

2.3. Wykorzystanie testów punktowych do identyfikacji funkcji przynależności

Podawane w literaturze medycznej przykłady testów punktowych stosowanych w procesie diagnozy wraz ze zgromadzą bazą danych mogą być wykorzystane do automatycznego wyznaczania reguł Sugeno [12], a co za tym idzie, do określenia funkcji przynależności o kształcie trójkątnym (rys.4). Metoda została szerzej omówiona w [11]. Pozwala ona uniezależnić się od bieżącej współpracy z ekspertem medycznym, a co za tym idzie, oszczędzić jego czas, a także wykorzystać wszystkie posiadane zaczerpnięte z bazy szpitalnej dane. Przy nieco większym nakładzie obliczeniowym można wyznaczyć funkcje przynależności w innej postaci (krzywe Gaussa, funkcje trapezowe). Wyznaczenie funkcji przynależności w postaci zaproponowanej na rys.4 jest korzystne z punktu widzenia efektywności wspomagania diagnozy, ponieważ pozwala na dobre zróżnicowanie reguł odnoszących się do poszczególnych zbiorów rozmytych. W przypadku funkcji z rys.3 praktycznie nie ma różnic w rezultatach wnioskowania dla reguł odnoszących się do niskich i bardzo niskich wartości parametru medycznego, podczas gdy dla funkcji z rys.4 różne reguły będą uaktywnione dla niskich wartości testu laboratoryjnego i wartości poniżej normy. Z pomocą identyfikacji rozmytej możliwe jest także równoczesne wyznaczanie funkcji przynależności dla dwóch zmiennych, np. ciśnienia skurczowego i rozkurczowego, co rozwiązuje problem definiowania funkcji przynależności dla złożonych symptomów.

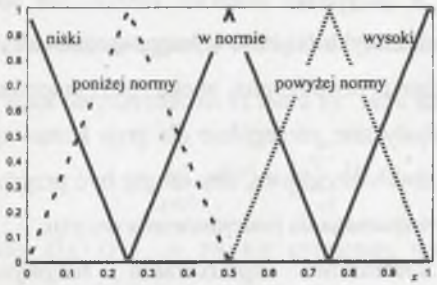

Rys.4. Funkcje przynależności wyznaczane w procesie identyfikacji rozmytej dla testu punktowego

Fig.4. Membership functions found during fuzzy identification process for a score test

2.4. Interpretowanie objawów w sposób precyzyjny i za pomocą skali

W każdym procesie diagnostycznym występują objawy, które muszą być jednoznacznie określone – np. płeć czy grupa krwi. Ich sformułowanie w języku naturalnym nie odbiega od wcześniej omówionych symptomów, ponieważ można powiedzieć „grupa krwi jest B Rh+", podobnie jak „ciśnienie skurczowe krwi jest wysokie". Dlatego takie parametry medyczne

można rozpatrywać z punktu widzenia przynależności do odpowiedniego zbioru, która przyjmuje jedną z dwóch wartości: 1 lub 0.

Wyróżnia się również objawy, których występowanie można ocenić w wybranej skali, jednak trudno zdefiniować dla nich dziedzinę. Dotyczy to wszystkich ocenianych lecz niemierzalnych parametrów medycznych, a więc bardzo wielu symptomów stwierdzanych na podstawie wywiadu i badania przedmiotowego. Definiowanie zbiorów rozmytych dla tych symptomów jest pożądane, lecz często trudne, ponieważ najpierw należy przyjąć przedział, w jakim parametr będzie oceniany, następnie zbudować na nim zbiory rozmyte. O ile postępowanie takie jest kłopotliwe, lepiej jest poprzestać na dobraniu dowolnej skali, a następnie przeliczeniu jej na przedział [0,1]. Przykładem objawów, dla których takie działanie jest wskazane, mogą być: „zwiększona pobudliwość nerwowa", „osłabienie siły mięśniowej" lub „ból".

3. Zgodność obserwowanego objawu i przesłanki reguły diagnostycznej

Niezależnie od tego, w jaki sposób sformułowany jest objaw w regule diagnostycznej, w chwili uruchamiania tej reguły dla danych dotyczących konkretnego pacjenta ważna staje się zgodność tych danych z przesłanką reguły. Zgodność ta w przypadku zbioru rozmytego ma wartość funkcji przynależności, np. zgodność ciśnienia skurczowego krwi 170 mmHg z przesłanką „wysokie ciśnienie skurczowe" wynosi: $\mu_{\text{WYSOKIE CIŚNIENIE SKURCZOWE}}(170) = 0.8$. W przypadku bólu w skali od 1 do 10, gdy pacjent oceni go na 7, można tę zgodność scharakteryzować liczbą 0.7. Zgodność danych pacjenta (w przeciwieństwie do pacjentki) z płcią męską wynosi 1. Tak więc dla rozmaicie formułowanych objawów cechą wspólną i jedynie ważną w dalszych krokach wnioskowania jest owa zgodność, która będzie dalej opisana symbolem η.

4. Związek między objawem i diagnozą

Związek między przesłanką reguły a jej konkluzją rzadko jest całkowicie pewny. Jednym z największych osiągnięć systemu ekspertowego MYCIN było wprowadzenie współczynnika pewności wniosku na podstawie przesłanki tzw. CF (ang. Certainty factor) [9]. W literaturze medycznej związek ten jest często opisywany przez podanie tabel częstościowo wyznaczonego prawdopodobieństwa występowania objawu pod warunkiem choroby i jej

braku. Sposobem wyrażenia tego związku są również testy punktowe. Testy te można zamodelować za pomocą następującej reguły:

Jeżeli objaw S jest A_i, to $suma := suma + p_i$.

Ryzyko choroby ocenia się następnie za pomocą *sumy*. Jeżeli *suma* jest większa od pewnego progu, wskazuje to uzasadnione podejrzenie choroby. Testy pomagają ocenić łączny wpływ wielu objawów na diagnozę.

Jak wynika z powyższych spostrzeżeń, związek pomiędzy przesłanką reguły a wnioskiem jest określany przez jedną liczbę, otrzymywaną na podstawie prawdopodobieństwa, lecz bardzo rzadko będącą prawdopodobieństwem warunkowym. Liczne założenia związane z tym ostatnim (m. in. Niezależność objawów, wartości prawdopodobieństwa a priori choroby) czynią je nieprzydatnym jako miara omawianego związku. Istnieje jednak możliwość wykorzystania informacji statystycznych oraz heurystycznych do określenia miary pewności poprzez zastosowanie teorii Dempstera-Shafera.

3.1. Teoria Dempstera-Shafera we wspomaganiu diagnozy medycznej

W teorii Dempstera-Shafera [5] wiedza o rozwiązywanym problemie jest reprezentowana w postaci tzw. funkcji zaufania (oznaczanej przez *Bel* – ang. „belief"). Teoria stanowi próbę sformalizowania wnioskowania „poszlakowego" [13], pozwalającego na wyprowadzenie konkluzji z przesłanek, które są nieprecyzyjne i/lub niekompletne. Określenie funkcji zaufania *Bel* do hipotezy jest możliwe na podstawie zdefiniowanych uprzednio tzw. elementów ogniskowych, czyli zdań, a w przypadku wnioskowania – przesłanek, o których posiadamy informacje. Informacje te wyraża tzw. bazowy rozkład prawdopodobieństwa. Można go ustalić na podstawie bazy danych lub zaczerpnąć z opracowań literaturowych. Zdania nie muszą być rozłączne ani elementarne, dlatego każda informacja może być wykorzystana w procesie wnioskowania.

Bazowy rozkład prawdopodobieństwa m jest określony w następujący sposób [5, 13]:

$$m(f) = 0, \qquad (2)$$

$$\sum_{a \in T} m(a) = 1,$$

gdzie f oznacza zdanie fałszywe, a T zbiór elementów ogniskowych. Jeżeli przesłanka b wskazuje na hipotezę a ($b \Rightarrow a$), to wartość zaufania do hipotezy a na podstawie informacji o b wylicza się jako:

$$Bel(a) = \sum_{(b \Rightarrow a) = t} m(b), \tag{3}$$

gdzie t oznacza prawdę.

W ramach teorii Dempstera-Shafera możliwe jest łączenie informacji pochodzącej z dwóch źródeł (dwóch rozkładów bazowych prawdopodobieństwa), zgodnie ze wzorem [4]:

$$\forall_{a \neq f} \; m(a) = \frac{\sum_{b \wedge c = a} m_1(b) \cdot m_2(c)}{\sum_{b \wedge c \neq f} m_1(b) \cdot m_2(c)} \tag{4}$$

Bazowy rozkład prawdopodobieństwa może stanowić miarę wagi poszczególnych objawów w procesie diagnozy. Tak więc reguła stanowiąca element bazy wiedzy wygląda następująco:

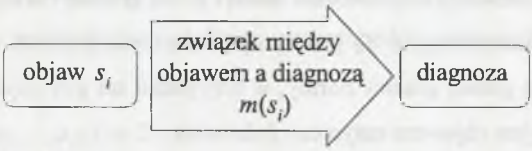

Z kolei wartość funkcji zaufania wyliczana jako suma wartości bazowego rozkładu prawdopodobieństwa dla reguł uruchomionych po stwierdzeniu zgodności objawów obserwowanych u pacjenta i z ich przesłankami daje obraz pewności diagnozy. W zastosowaniu medycznym oblicza się wartość funkcji zaufania przynajmniej dla dwóch diagnoz: „zdrowie" i „choroba". Elementami ogniskowymi są ich symptomy. Niezwykle ważny jest brak założeń o niezależności objawów, ponieważ często się zdarza, że ten sam objaw musi być w czasie wnioskowania rozpatrywany dwukrotnie – samodzielnie oraz w połączeniu z innym symptomem. Tworzy się reguły, które przyporządkowują symptomy do odpowiednich diagnoz. Symptomy często odnoszą się do tych samych parametrów medycznych, ale do różnych diagnoz, zwłaszcza w przypadku testów laboratoryjnych. Wynik testu w przedziale norm jest symptomem zdrowia, powyżej górnej granicy normy może być objawem jednej choroby, a poniżej dolnej granicy – objawem innej. W ten sposób ustalenie norm pociąga za sobą określeniem reguł wnioskowania.

Wartość zaufania dla danej diagnozy oblicza się na podstawie symptomów obserwowanych u danego pacjenta. Jednakże u badanego pacjenta zazwyczaj obecne są zarówno symptomy potwierdzające diagnozę (np. „choroba"), jak również wskazujące na konkurencyjną hipotezę (np. „zdrowie"). Część objawów może pozostać nieznana.

Z powyższej interpretacji wynika, że najważniejszym źródłem informacji obok reguł diagnostycznych jest bazowy rozkład prawdopodobieństwa. Dlatego podstawą właściwego

wnioskowania musi być staranne określenie jego wartości dla każdego symptomu i każdej reguły.

3.2. Wyznaczanie bazowego rozkładu prawdopodobieństwa

W celu wyznaczenia bazowego rozkładu prawdopodobieństwa (brp) należy najpierw zdefiniować symptomy i diagnozy. Niech będą dane dwie diagnozy: choroba (D) i zdrowie (H). Niech symptom będzie zdefiniowany jako parametr medyczny w relacji do normy:

$$symptom \equiv parametr < relacja > norma,$$

np. $\{ parametr_i < norma\downarrow \} \equiv s_{Di},$

$$\{ parametr_i \in [norma\downarrow, norma\uparrow] \} \equiv s_{Hi},$$

gdzie: $norma\downarrow$, $norma\uparrow$ oznaczają odpowiednio dolną i górną granicę normy.

Przykładowo, test laboratoryjny T_3 jest symptomem nadczynności tarczycy, jeśli jego rezultat wypada powyżej górnej granicy normy, w przypadku zaś gdy daje wynik w przedziale norm górnej i dolnej, jest objawem eutyreozy (zdrowia).

Symptom złożony jest koniunkcją dwóch symptomów:

$$s_{Di1} \wedge s_{Di2} \equiv s_{Di}.$$

Dla uproszczenia oznaczeń załóżmy, że:

$$\{s_{D1}, \dots, s_{Dk}\} \cap \{s_{H1}, \dots, s_{Hn}\} = \varnothing,$$

$$\{s_{D1}, \dots, s_{Dk}\} \Rightarrow D \quad \{s_{H1}, \dots, s_{Hn}\} \Rightarrow H.$$

Dla tak zdefiniowanych symptomów można określić bazowy rozkład prawdopodobieństwa spełniający:

$$m(f) = 0, \tag{5}$$

$$\sum_{s_i \in S_D} m(s_i) = 1,$$

gdzie f oznacza symptom pusty (brak jakiegokolwiek symptomu), a S_D zbiór symptomów (prostych lub złożonych) związanych z diagnozą D.

Proponuje się następujące definicje brp:

1) „płaski" brp:

$$m_D(f) = 0;\ \{s_{D1}, \dots, s_{Dk}\} \Rightarrow D, \text{ stąd } m_D(s_{Di}) = \frac{1}{k}; \tag{6}$$

$$m_H(f) = 0;\ \{s_{D1}, \dots, s_{Hn}\} \Rightarrow H, \text{ stąd } m_H(s_{Hi}) = \frac{1}{n};$$

oznacza, że wszystkie objawy są jednakowo ważne w procesie diagnozy. Jest to przypadek trywialny, pozwala jednak na modelowanie wnioskowania, kiedy nic nie wiadomo o wadze objawów,

2) brp oparty na ocenach heurystycznych lub testach punktowych. Punktację z podawanych w literaturze medycznej testów można uważać za wartościowanie wagi różnych objawów w diagnozie. Można więc zdefiniować brp jako:

$$m_D(f) = 0\,;\ \{s_{D1}, \dots, s_{Dk}\} \Rightarrow D\,,\ \text{stąd}\ m_D(s_{Di}) = \frac{p_{Di}}{\sum\limits_{j=1,\dots k} p_{Dj}}, \tag{7}$$

$$m_H(f) = 0\,;\ \{s_{D1}, \dots, s_{Hn}\} \Rightarrow H\,,\ \text{stąd}\ m_H(s_{Hi}) = \frac{p_{Hi}}{\sum\limits_{j=1,\dots k} p_{Hj}},$$

3) brp oparty na danych statystycznych. Mając do dyspozycji bazę danych brp można określić z wykorzystaniem częstościowej definicji prawdopodobieństwa do obliczeń $P(s_{Di}/D)$, $P(s_{Di}/\neg D)$:

$$m_D(f) = 0\,;\ \{s_{D1}, \dots, s_{Dk}\} \Rightarrow D\,,$$

$$m_D(s_{Di}) = \begin{cases} \dfrac{P(s_{Di}/D) - P(s_{Di}/\neg D)}{\sum\limits_{j=1,\dots,k} [P(s_{Dj}/D) - P(s_{Dj}/\neg D)]} & P(s_{Di}/D) - P(s_{Di}/\neg D) > 0 \\ 0 & \textit{w przeciwnym przypadku} \end{cases} \tag{8}$$

Analogicznie definiuje się brp dla diagnozy H. Według (8) definiuje się brp, gdy w bazie danych dysponujemy grupą kontrolną. Oprócz osób zdrowych do zbioru $\neg D$ należy również zaliczyć pacjentów cierpiących na inne choroby niż D. Na przykład o ile D - pacjenci z nadczynnością tarczycy, to $\neg D$ – pacjenci bez choroby tarczycy lub z niedoczynnością tarczycy. W przypadku braku możliwości ustalenia danych dla grupy kontrolnej (np. dla bardzo rzadkich chorób, które rozpoznaje się na podstawie specjalistycznych badań) można zdefiniować brp jako:

$$m_D(f) = 0\,;\ \{s_{D1}, \dots, s_{Dk}\} \Rightarrow D\,,$$

$$m_D(s_{Di}) = \begin{cases} \dfrac{P(s_{Di}/D) - P(\neg s_{Di}/D)}{\sum\limits_{j=1,\dots k} [P(s_{Dj}/D) - P(\neg s_{Dj}/D)]} & P(s_{Di}/D) - P(\neg s_{Di}/D) > 0 \\ 0 & \textit{w przeciwnym przypadku} \end{cases} \tag{9}$$

Przy zastosowaniu (8), (9) do obliczeń brp można eliminować symptomy, które w rozpatrywanej populacji wskazują na inną diagnozę, niż przyjmuje się to standardach

diagnostycznych. Dotyczy to zawsze jedynie mniej ważnych, pomocniczych objawów, lecz gdy jest ich bardzo wiele w znaczący sposób mogą one fałszować diagnozę.

Oczywiście, im mniej liczne (mniej doskonałe) dane, tym gorzej określony jest brp. Niemniej, możliwość uniknięcia przekształcenia $P(s_{Di}/D)$ na $P(D/s_{Di})$ zgodnie ze wzorem Bayesa, gdzie potrzebne jest prawdopodobieństwo a priori $P(D)$, jest ważną korzyścią z zastosowania wartości brp w miejsce klasycznego prawdopodobieństwa warunkowego.

3.3. Łączenie bazowych rozkładów prawdopodobieństwa

Zgodnie z (4) można łączyć dwa brp zdefiniowane dla dwóch baz danych lub dla jednej bazy danych i oceny heurystycznej, obliczając wartość brp dla jednakowo zdefiniowanych symptomów:

$$\forall_{s_{Di}\neq f} \; m_D(s_{Di}) = \frac{\sum_{s_{Di}\wedge s_{Di}=s_{Di}} m_{D1}(s_{Di})\cdot m_{D2}(s_{Di})}{\sum_{s_{Dj}\wedge s_{Dj}\neq f \; j=1,\dots,k} m_{D1}(s_{Dj})\cdot m_{D2}(s_{Dj})} = \frac{m_{D1}(s_{Di})\cdot m_{D2}(s_{Di})}{\sum_{s_{Dj}\neq f \; j=1,\dots,k} m_{D1}(s_{Dj})\cdot m_{D2}(s_{Dj})} \tag{10}$$

Czasami należy połączyć informację pochodzącą z dwóch różnych baz danych o podobnym, lecz nie identycznym sposobie formułowania symptomów. W szczególności chodzi o połączenie dwóch baz danych, w których występują odpowiednio zbiory symptomów:

- baza I : $\{s_{D1}, \dots, s_{Dk}, s_C\} \Rightarrow D$,
- baza II : $\{s_{D1}, \dots, s_{Dk}, s_{Dk+1}, \dots, s_{Dk+m}\} \Rightarrow D$.

Symptom $s_C = (s_{Dk+1} \vee \dots \vee s_{Dk+m})$ zastępuje łączny wpływ symptomów $s_{Dk+1}, \dots, s_{Dk+m}$ na diagnozę. Aby dokonać łączenia brp obliczonych dla każdej z baz z osobna, należałoby rozpatrzyć koniunkcję s_C z każdym z możliwych podzbiorów $\{s_{Dk+1}, \dots, s_{Dk+m}\}$ (oznaczmy go przez S_{Dkm}), przy czym: $(s_{Dk+1} \vee \dots \vee s_{Dk+m}) \wedge S_{Dkm} \equiv S_{Dkm}$. Każdy z symptomów jest jednakowo uprawniony do występowania w podzbiorach S_{Dkm}, a w praktycznych przypadkach wartość brp w bazie II dla dowolnego podzbioru będzie wielokrotnie mniejsza od wartości brp dla jednego symptomu. Będzie ona tym mniejsza, im więcej symptomów będzie stanowiło podzbiór, ponieważ trudno jest znaleźć pacjentów o podobnych zestawach danych. Można więc przyjąć ważkie, lecz z punktu widzenia zastosowania uzasadnione założenie, że rozpatrywane będą tylko podzbiory składające się z jednego symptomu. W takim przypadku łączny brp można obliczyć jako:

$i=1,\dots,k$

$$\forall_{s_{Di}\neq f}\; m_D(s_{Di}) = \frac{\sum_{s_{Di}\wedge s_{Di}=s_{Di}} m_{D1}(s_{Di})\cdot m_{D2}(s_{Di})}{\sum_{s_{Dj}\wedge s_{Dj}\neq f\; j=1,\dots,k} m_{D1}(s_{Dj})\cdot m_{D2}(s_{Dj}) + \sum_{s_{dj}\wedge s_{dj}\neq f\; j=k+1,\dots,k+n} m_{D1}(s_C)\cdot m_{D2}(s_{Dj})} =$$

$$= \frac{m_{D1}(s_{Di})\cdot m_{D2}(s_{Di})}{\sum_{s_{Dj}\neq f\; j=1,\dots,k} m_{D1}(s_{Dj})\cdot m_{D2}(s_{Dj})\left[1+\frac{\sum_{s_{Dj}\neq f\; j=k+1,\dots,k+n} m_{D1}(s_C)\cdot m_{D2}(s_{Dj})}{\sum_{s_{Dj}\neq f\; j=1,\dots,k} m_{D1}(s_{Dj})\cdot m_{D2}(s_{Dj})}\right]} = \tag{11}$$

$$= \frac{m_{D1}(s_{Di})\cdot m_{D2}(s_{Di})}{\left[\sum_{s_{Dj}\neq f\; j=1,\dots,k} m_{D1}(s_{Dj})\cdot m_{D2}(s_{Dj})\right][1+w]}$$

W zależności (11) w jest wskaźnikiem obrazującym wagę symptomu s_C na tle pozostałych objawów. Podobnie dla reszty symptomów można obliczyć:

$i=k+1,\dots,k+n$

$$\forall_{s_{Di}\neq f}\; m_D(s_{Di}) = \frac{\sum_{s_{Di}\wedge s_{Di}=s_{Di}} m_{D1}(s_C)\cdot m_{D2}(s_{Di})}{\sum_{s_{Dj}\wedge s_{Dj}\neq f\; j=1,\dots,k} m_{D1}(s_{Dj})\cdot m_{D2}(s_{Dj}) + \sum_{s_{dj}\wedge s_{dj}\neq f\; j=k+1,\dots,k+m} m_{D1}(s_C)\cdot m_{D2}(s_{Dj})} =$$

$$= \frac{m_{D1}(s_C)\cdot m_{D2}(s_{Di})}{\sum_{s_{Dj}\neq f\; j=1,\dots,k} m_{D1}(s_C)\cdot m_{D2}(s_{Dj})\left[1+\frac{\sum_{s_{Dj}\neq f\; j=1,\dots,n} m_{D1}(s_{Dj})\cdot m_{D2}(s_{Dj})}{\sum_{s_{Dj}\neq f\; j=k+1,\dots,k+m} m_{D1}(s_C)\cdot m_{D2}(s_{Dj})}\right]} = \frac{m_{D2}(s_{Di})}{\left[\sum_{s_{Dj}\neq f\; j=1,\dots,n} m_{D2}(s_{Dj})\right]\left[1+\frac{1}{w}\right]} \tag{12}$$

Z powyższych zależności wynika, że daleko idące założenie przynosi wymierne korzyści w zastosowaniu: pozwala ocenić wpływ części symptomów, np. wydzielonych w postaci testu punktowego na całość diagnozy.

Łączenie brp można, oczywiście, rozszerzyć opierając się za każdym razem na dwóch rozkładach (np. wynikowym z poprzednich dwóch rozkładów oraz brp obliczonym na podstawie bazy II). Ta właściwość teorii Dempstera-Shafera czyni ją niezwykle przydatną we wspomaganiu diagnozy medycznej, ponieważ pozwala na uwzględnienie informacji o leczonej populacji, trendów w innych populacjach oraz ogólnie przyjętych zasad diagnostycznych w ramach jednego, spójnego procesu wnioskowania.

4. Obliczanie pewności diagnozy

Wartość funkcji zaufania dla diagnozy postawionej na podstawie symptomów obserwowanych u pacjenta można wyznaczyć w sposób pokazany na rys.5.

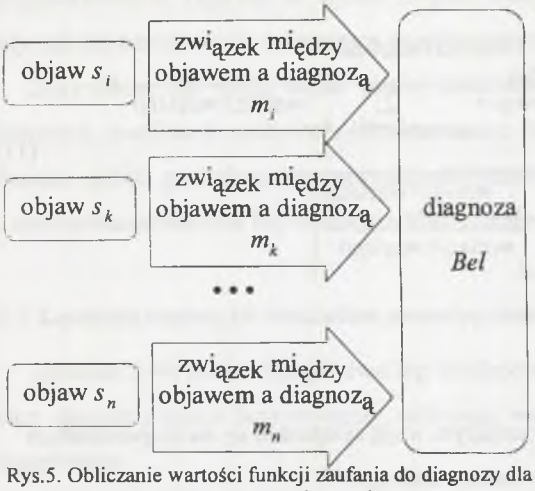

Rys.5. Obliczanie wartości funkcji zaufania do diagnozy dla objawów zaobserwowanych u pacjenta

Fig.5. Belief function values calculation for symptoms found in a patient

Wartość funkcji zaufania (3) ustalaną dla diagnozy D podczas badania pacjenta bez rozpatrywania pewności i precyzyjności symptomów oblicza się jako:

$$Bel(D) = \sum_{(s_i \Rightarrow D)=t} m_D(s_i) . \quad (13)$$

Wyznaczanie pewności diagnozy wiąże się z uruchomieniem reguł wnioskowania, których przesłanki zgadzają się z danymi pacjenta w założonym stopniu η. Zgodnie z (13), wartość funkcji zaufania dla diagnozy D można obliczyć opierając się na symptomach wskazujących tę diagnozę, zgodnych z przesłankami reguł w stopniu η, jako:

$$Bel(D) = \sum_{(s_{Di}^{\eta} \Rightarrow D)=t} m_D(s_{Di}) . \quad (14)$$

W ten sposób gdy maleje η, rośnie *Bel*, a minimalna i maksymalna wartość funkcji zaufania ilustrują pewność diagnozy.

5. Przykład

Jako przykład obliczeń przeprowadzonych z wykorzystaniem zaproponowanych czynników nieprecyzyjności i niepewności w diagnozie medycznej posłuży problem

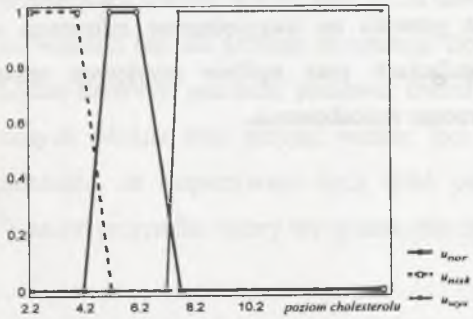

Rys.6. Funkcje przynależności dla jednego z parametrów labortoryjnych

Fig.6. Membership functions for a laboratory test

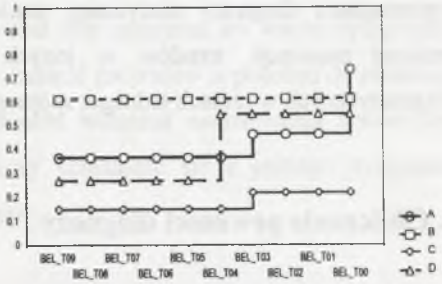

Rys.7. Wartości *Bel* dla czterech pacjentów uzyskane dla różnych wartości progowych η

Fig.7. Belief values for four patients and several η threshold values

wspomagania diagnozy „zdrowie" dla grupy 40 „zdrowych" pacjentów, których dane zostały zebrane pod kątem chorób tarczycy. Dla diagnozowanych pacjentów zbadano 10 symptomów prostych i złożonych. Sformułowano 10 reguł diagnostycznych. Symptomy były zdefiniowane za pomocą zbiorów rozmytych, wyznaczonych na podstawie danych statystycznych dla 3 grup pacjentów: nie cierpiących na choroby tarczycy, z nadczynnością tarczycy i z niedoczynnością tarczycy. Przykład uzyskanych funkcji przynależności pokazano na rys.6. Obliczono wartości funkcji zaufania dla $\eta \in [0,1]$, zmieniając próg stopnia zgodności co 0.1. Przykładowe trendy wartości *Bel* dla zmieniającego się progu zgodności η pokazuje rys.7. Reprezentowana jest tu diagnoza o wysokim stopniu zaufania, który nie zmienia się ze zmniejszaniem się η (pacjent B). Można ją określić jako pewną. Mniej pewna jest diagnoza dla pacjenta A, mimo iż jej wartość maksymalna *Bel* jest większa niż w poprzednim przypadku, ponieważ wartość tę otrzymano dla najniższego η. Dla wyższych wartości progowych zgodności była ona znacznie niższa. W przypadku pacjenta C wartości *Bel* nie potwierdzają diagnozy, ponieważ pozostają one niskie dla wszystkich η, należy przyjąć, że zaufanie do diagnozy „zdrowie" jest niskie. Dalsze badania będą potrzebne, by postawić diagnozę dla pacjenta D, gdyż wartości zaufania zmieniają się znacznie dla zmiany progu.

Należy zauważyć, że właściwe wspomaganie polega na obliczeniu wartości *Bel* dla różnych diagnoz (np. nadczynność tarczycy, „zdrowie", niedoczynność tarczycy) i porównaniu tych wartości. Umożliwia to poprawne wnioskowanie w przypadku gdy znamy niewiele objawów. Przeprowadzenie tej analizy wykracza jednak poza ramy niniejszego artykułu.

Z analizy wartości maksymalnych i średnich *Bel* obliczonych dla 40 pacjentów wynikają omówione dalej wnioski.

Stałą wartość *Bel* (wszystkie objawy jednakowo precyzyjne) w zależności od progowych wartości η_p ($\eta \geq \eta_p$) otrzymano dla liczby pacjentów wskazanej w drugiej kolumnie tab.1.

Tabela 1

η_p	Liczba pacjentów, dla których *Bel*=const	Liczba błędów w diagnozie
0.0	17	4
0.3	22	5
0.5	31	5
0.7	36	7
0.9	40	7

Można uważać, że diagnoza jest tym pewniejsza, im mniejszym wahaniom podlegają wartości *Bel* w zależności od progu zgodności. Z tabeli wynika, że przyjęcie progu 0.5, często

obecnego w zastosowaniach jako intuicyjna wartość graniczna, zapewnia właściwą jakość diagnozy. W przykładzie przy progu $\eta \geq 0.5$ otrzymano stałą wartość *Bel* dla 31 pacjentów (77.5%).

W trzeciej kolumnie tab.1. scharakteryzowano rozbieżności między opinią lekarzy a rezultatami obliczeń przy różnych progach η. Jako poprawną diagnozę przyjęto $Bel > 0.2$, ponieważ z jednej strony, jak wynika z wcześniejszych doświadczeń [10], wartości *Bel* wyliczane dla zastosowań medycznych generalnie są znacząco mniejsze od 1, a z drugiej strony w analizowanym przykładzie niższe wartości diagnozy zasadniczej były podstawą do diagnozy konkurencyjnej. Także w przypadku analizy trafności sugestii systemu można uznać, że próg 0.5 jest właściwym poziomem zgodności. Należy tutaj zauważyć, że dla dwóch pacjentów otrzymano $Bel = 0.0$ niezależnie od η, a więc należałoby ich dane pominąć w analizie. Wówczas 92,2% pacjentów byłoby właściwie zaklasyfikowanych dla preferowanego progu $\eta \geq 0.5$.

Można więc przyjąć, że zaproponowane czynniki pewności i precyzyjności we właściwy sposób opisują proces diagnozy.

6. Wnioski

Wspomaganie diagnozy medycznej wymaga uwzględnienia czynników pewności i precyzyjności. Zaproponowana metoda opisu czynników pewności z zastosowaniem teorii Dempstera-Shafera umożliwia zgodny z intuicją i zrozumiały dla lekarzy sposób modelowania związku między objawem a diagnozą oraz pewności diagnozy. Pozwala ona także na wykorzystanie prawie każdej dostępnej informacji wraz z odpowiednim opisem jej jakości (pewności). Zastosowanie bazowego rozkładu prawdopodobieństwa zamiast prawdopodobieństwa warunkowego, a co za tym idzie, wyeliminowanie z obliczeń prawdopodobieństwa a priori $P(D)$ jest ważną korzyścią płynącą z zastosowania tej metody. Możliwość łączenia informacji pochodzącej z różnych źródeł, a zwłaszcza rozpatrzenie danych specyficznej populacji na tle informacji literaturowych czyni tę metodę istotnie przydatną we wspomaganiu diagnozy medycznej. Nie bez znaczenia jest również łatwość jej implementacji w postaci programu komputerowego.

Oprócz czynników pewności w diagnozie medycznej ważna jest także precyzyjność formułowania symptomów. Istotną zaletą jest możliwość zastosowania zbiorów rozmytych w procesie wspomagania diagnozy medycznej. Pozwala to m.in. na wykorzystanie mało licznych danych, które nie mogą być źródłem statystycznie istotnego opisu lub podstawą

uczenia sieci neuronowej. Zaproponowany w niniejszej pracy sposób jednolitej interpretacji objawów „precyzyjnych", „skalowanych" i „rozmytych" przy wprowadzonym pojęciu progu zgodności pozwala zobiektywizować jakość diagnozy bez komplikacji obliczeń i przy zachowaniu wartości funkcji zaufania jako miary jej trafności.

Zaprezentowana metoda może być przydatna w automatycznym wspomaganiu diagnozy medycznej dla problemów cechujących się krótkim, łańcuchem wnioskowania (symptom(y) ⇒ diagnoza), licznymi parametrami medycznymi występującymi we wnioskowaniu oraz koniecznością łączenia informacji pochodzących z przynajmniej dwóch źródeł. Może być użyteczną alternatywą wobec skomplikowanych systemów ekspertowych.

Literatura

1. Akay M.: From the Guest Editor, IEEE Engineering in Medicine and Biology, Application of Fuzzy Logic, Vol. 13 No 5 ss. 665-666, Nov/Dec 1994.
2. Bartelheimer H., Jones A. (red.): Kliniczna diagnostyka czynnościowa. PZWL, Warszawa 1972, ss. 20-21.
3. Bastian A.: Identifying fuzzy rule-based models using soft computing, Proc. EUFIT'98, ss. 589-593.
4. Bolc L., Borodziewicz W., Wójcik M.: Podstawy przetwarzania informacji niepewnej niepełnej. PWN, Warszawa 1991
5. Gordon J, Shortliffe E. H.: The Dempster-Shafer Theory of Evidence. Rule -Based Expert Systems. Buchanan B.G., Shortliffe E.H. edts, Addison Wesley,1984, ss.272-292.
6. Górnicki T.: Choroby tarczycy, PZWL, Warszawa 1988, ss. 123-138.
7. Iliad, Widows-Based Diagnostic Decision Support Tools for Internal Medicine, User Manual. Applied Medical Informatics, May 1994.
8. Schuerz M., Hipf G., Grabner G.: An assessment of different approaches to defining fuzzy membership functions semi-automatically, in K.-P. Adlassnig; Fuzzy diagnostic and therapeutic Decision Support Proc. ERUDIT-Workshop, Austia, May 2000, ss. 129-137.
9. Shortliffe E.H.: Computer-Based Medical Consultations: MYCIN. Elsevier, New York-Oxford-Amsterdam 1976.
10. Straszecka E., Straszecka J.: Computerization of score tests in medicine – problems and possible solution. Medical & Biological Engineering & Computing Vol. 37, Sup. 2, Part I (Proc. EMBEC'99), pp. 752-753.

11. Szczepaniak P. S., Lisboa P.J.G., Kacprzyk J. (edts): Fuzzy systems in medicine, Physica-Verlag, Heidelberg 2000, ss. 32-47.
12. T.Takagi, M.Sugeno: Fuzzy Identification of Systems and Its Applications to Modeling and Control. IEEE Trans. on Systems, Man & Cybernetics, Vol.SMC-15, No.1, pp.116-132: Jan./Feb. 1985.
13. Wierzchoń S.T.: Metody reprezentacji i przetwarzania informacji niepewnej w ramach teorii Dempstera-Shafera. Instytut Podstaw Informatyki PAN, 1996.
14. Wydrzyński L.: INFARCTEST- Prognostyczny System Ekspertowy, podręcznik użytkownika. POLGAT, Polska, 1990.

Recenzent: Dr hab. Józef Drewniak

Abstract

The paper aims at unifying knowledge and certainty description in medical diagnosis support systems and preserving intuitively right form the point of view of a user interpretation of a predicate and a conclusion of a diagnostic rule.

Methods of symptom are imprecision and uncertainty of dependence between a symptom and a diagnosis defining are proposed in the paper. A predicate and a conclusion of a diagnostic rule are defined and an interpretation of the predicate imprecision, despite of its determining as a fuzzy set, a scale or a crisp value 0 or 1 is given. Possibilities and limitations in fuzzy set membership function defining in medical problems are commented.

A method of inference based on Dempster-Shafer theory of evidence, which allows using a variety of information: heuristic, statistic and found on diagnostic algorithms transformation, is presented. Standards for basic probability assignment determination in Dempster-Shafer theory as well as combining information coming form different sources are proposed. Results of diagnosis support for patients at thyroid gland diseases risk are shown as an example. Important advantages of the proposed method medical diagnosis support and some limitations in its application are pointed out.