

LÓGICA DIFUSA

Júlio Cesar Nievola ★
Renato Garcia Ojeta ★ ★

RESUMO

Este artigo aborda o caso da teoria dos conjuntos em que a pertinência de um elemento está além do caso pertence ou não-pertence. Embora existam várias abordagens, a aqui apresentada inclui a Teoria Clássica dos Conjuntos como um caso particular. Valores exatos de pertinência não existem; eles são índices de tendência que são determinados subjetivamente por alguém ou por um grupo. Além disso, eles são dependentes do contexto.

Os conjuntos difusos são considerados uma forma apropriada de trabalhar com a incerteza, concluindo-se que decisões tomadas com tal base devem ser intrinsecamente difusas. Eles são inapropriados para a apresentação da decisão e um formato numérico, sendo muito melhor uma declaração em linguagem natural.

ABSTRACT

This paper deals with set theory when membership is no longer an all-or-nothing notion. There is no unique way to build such a theory. But, the alternative approach presented here include ordinary set theory as a particular case. Precise membership values do not exist by themselves, they are tendency indices that are subjectively assigned by an individual or a group. Moreover, they are context dependent.

Fuzzy sets are assumed to be an appropriate way of dealing with uncertainty, and it is therefore concluded that decisions taken on the basis of such information must themselves be fuzzy. It is inappropriate then to present the decision in numerical form; a statement in natural language is much better.

Fuzzy set theory has a number of properties that make it suitable for formalizing the uncertain information upon which medical diagnosis and treatment is usually based.

1. INTRODUÇÃO AOS CONJUNTOS DIFUSOS

Importância da Representação Difusa

Na vida real os fatos e afirmações estão formulados com um certo grau de incerteza. Precisão é apenas uma abstração. A abstração pode ser definida como a habilidade humana de reconhecer e selecionar as propriedades relevantes dos fenômenos e objetos do mundo real.

A abstração não é um conceito estático. O processo de abstração é contínuo e está produzindo constantemente novos resultados. Desta forma, o conhecimento é sempre e necessariamente incompleto.

A representação difusa tem várias propriedades que a tornam indicada para a formalização da informação humana. Primeiro, ela define entidades inexatas como conjuntos difusos. A seguir, fornece uma aproximação lingüística da situação, tal como ocorre com os seres humanos que utilizam palavras em vez de números para se expressar. Finalmente, a lógica difusa oferece métodos de raciocínio apropriados a inferências aproximadas.

Representação de Conjuntos Difusos

Na teoria clássica dos conjuntos temos a noção de que um elemento pertence ou não pertence a um conjunto. Entretanto, na vida real, a "pertinência" a um conjunto não é algo tão bem determinado. A teoria dos conjuntos difusos está baseada no fato de que certos conjuntos têm limites imprecisos.

Conjuntos difusos são aqueles mal-especificados, nos quais a pertinência ou não ao conjunto é gradual, em vez de abrupta. Se definimos U denotando um universo de discurso que pode ser uma coleção de objetos e A é um subconjunto finito de U , cujos elementos são u_1, u_2, \dots, u_n ; A pode ser expresso como:

$$A = \{u_1, u_2, u_3, u_4, \dots, u_n\}$$

Um subconjunto difuso finito A de U é um conjunto de pares ordenados:

$$A = \{(u_i, \mu_A(u_i))\} \text{ com } u_i \in U \text{ e } \mu_A(u_i) \in [0, 1]$$

onde $\mu_A(u_i)$ representa o grau de pertinência de u_i pertencer a A .

Outras representações para conjuntos difusos são:

$$A = \sum_{i=1}^n u_i / \mu_A(u_i) \quad \text{para } A \text{ finito}$$


$$A = \int_1 u_i / \mu_A(u_i) \quad \text{para } A \text{ infinito}$$

* Júlio Cesar Nievola é, Mestre em Engenharia Elétrica pela UFSC; professor do CEFET-PR; doutorando pela UFSC.


** Renato Garcia Ojeta é, Mestre em Engenharia Elétrica pela UFSC; professor da Universidade do Chile; doutorando pela UFSC.

Exemplos

1) "João é criança".



2) "Número inteiro maior que 5".



Operações com Conjuntos Difusos

Existem várias abordagens para definir as operações com conjuntos difusos, sendo a mais utilizada aquela indicada por Zadeh^{(5),(6),(7)}, que é apresentada a seguir.

Sejam A, B, C conjuntos difusos, e

$$\mu \in [0, 1] \text{ , então:}$$

Complemento de um Conjunto Difuso:

$$\mu_{A'}(x) = 1 - \mu_A(x);$$

onde $A' = \bar{A}$ é o complemento de A .

• União ou Disjunção:

$$\mu_C(x) = \max[\mu_A(x), \mu_B(x)] \text{ com } C = A \cup B$$


• Interseção ou Conjuncção:

$$\mu_C(x) = \min[\mu_A(x), \mu_B(x)] \text{ com } C = A \cap B$$

• Subconjunto:

$$A \subset B \text{ se } \mu_A(x) \leq \mu_B(x) \text{ para todo } x \in A$$

• Diagrama de Venn:



• **Propriedades:**

Considere A, B, C subconjuntos difusos de um universo de discurso X. Então, valem as propriedades:

a) *Comutatividade:*

$$A \cup B = B \cup A; A \cap B = B \cap A$$

b) *Associatividade:*

$$A \cup (B \cap C) = (A \cup B) \cap (A \cup C);$$

$$A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$$

c) *Idempotência:*

$$A \cup A = A; A \cap A = A$$

d) *Distributividade:*

$$A \cup (B \cap C) = (A \cup B) \cap (A \cup C)$$

$$A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$$

e) *Identidade:*

$$A \cup \phi = A; A \cap X = A$$

f) *Absorção:*

$$A \cup (A \cap B) = A; A \cap (A \cup B) = A$$

g) *Leis de De Morgan:*

$$\overline{(A \cap B)} = \bar{A} \cup \bar{B}$$

$$\overline{(A \cup B)} = \bar{A} \cap \bar{B}$$

h) *Involução:*

$$\bar{\bar{A}} = A$$

i) *Fórmula de Equivalência:*

$$(\bar{A} \cup B) \cap (A \cup \bar{B}) = (\bar{A} \cap \bar{B}) \cup (A \cap B)$$

j) *Fórmula de Diferença Simétrica:*

$$(\bar{A} \cap B) \cup (A \cap \bar{B}) = (\bar{A} \cup \bar{B}) \cap (A \cup B)$$

Observe que, entretanto:

$$A \cap \bar{A} \neq \phi; A \cup \bar{A} \neq X$$

• **Princípio de Extensão:**

O princípio de extensão permite levar para o campo dos conjuntos difusos, ou seja, "fuzificar", qualquer domínio do raciocínio matemático baseado na teoria de conjuntos. Usando este princípio, uma operação \star qualquer, pode ser estendida para \star , a fim de operar dois números difusos. Sejam M e N dois conjuntos difusos pertencentes ao universo U, e $x \in M, y \in N$. Então:

$$\mu_{M \star N}(z) = \sup \min [\mu_M(x), \mu_N(y)]$$



$$z = x \star y$$

Exemplo:

Se $\star = +; \star = + \text{ e } U = \mathbb{R}^+$

$$\mu_{M + N}(z) = \sup \min [\mu_M(x), \mu_N(y)]$$

$$z = x + y$$



$$\mu_{M + N}(z) = \mu_M(x_1) = \mu_N(y_1)$$

com $z = x_1 + y_1$

Qual é o grau de pertinência do resultado da soma ser 8?

Temos:

$$8 = 1 + 7 \Rightarrow \mu_M(1) = 0 \text{ e } \mu_N(7) = 0,5$$

Portanto, o mínimo dos dois é $\mu = 0$. Entretanto, temos também que:

$$8 = 2 + 6 \Rightarrow \mu_M(2) = 0,25 \text{ e } \mu_N(6) =$$

0,25, onde o mínimo é 0,25.

Assim sendo, para cada combinação de x e y que permite chegar ao resultado, temos que usar o mínimo. Tendo estes mínimos, o grau de pertinência mais elevado dos mesmos representará o grau de pertinência do resultado considerado, segundo o princípio de extensão.

Observa-se que o valor da expressão ocorrerá quando o grau de pertinência for o

mesmo em ambos os conjuntos M e N. Desta forma, computacionalmente adota-se o seguinte procedimento: para cada valor desejado de u, realiza-se a operação considerada entre os valores de $x \in M$ e $y \in N$ tais que

$$\mu_M(x) = \mu_N(y).$$


O resultado $z = x \star y$ terá o mesmo grau:

$$\mu_M \star N(z) = \mu_M(x) = \mu_N(y)$$

Para nosso exemplo de soma, teremos:

μ	x	y	z
0,00	1,0	5,0	06,0
0,25	2,0	6,0	08,0
0,50	3,0	7,0	10,0
0,75	4,0	8,0	12,0
1,00	5,0	9,0	14,0
0,00	6,0	10,0	16,0

Graficamente, temos como resultado:



Relações

No cálculo proposicional clássico, a expressão "Se A então B" onde A e B são variáveis proposicionais, é escrito como $A \rightarrow B$, com " \rightarrow " sendo um conectivo que é definido por:

$$A \rightarrow B \equiv \bar{A} \cup B$$

onde: \bar{A} indica o complemento de A.

Um conceito mais geral é a declaração difusa condicional:

"Se A então B" ou abreviadamente " $A \rightarrow B$ ",

na qual A é o antecedente ou premissa e B a conclusão, sendo ambos subconjuntos difusos, em vez de variáveis proposicionais. Uma relação R de A em B é um subconjunto difuso do produto cartesiano $U \times V$, onde $A \subset U$ e $B \subset V$. A declaração condicional:

"Se X é A então Y é B",

é representado pela relação difusa R e definida da seguinte forma:

$$\mu_R(u, v) = \min [\mu_A(u), \mu_B(v)] \text{ com } u \in U \text{ e } v \in V$$

Utilizando-se os conceitos vistos, pode-se partir para uma abordagem lógica de sistemas, onde a representação através de conjuntos difusos fornece uma interpretação mais próxima da humana, para os processos de raciocínio e inferência, servindo-se do modelo possibilístico.

2. LÓGICA DIFUSA

O Modelo Possibilístico

Seja x uma variável lingüística caracterizada por:

$$\{X, T(x), U, G, M\}$$

onde:

— X é o nome da variável (idade, altura, etc).

— T(x) é o conjunto de termos associados a x, isto é, seus valores lingüísticos (jovem, velho, não muito jovem, . . ., alto, baixo bastante alto, . . .);

— U é o universo de discurso (naturais entre 0 e 100);

— G é um conjunto de regras sintáticas que permitem gerar termos em T(x);

— M é uma regra semântica que associa a cada termo t de T(x) seu significado M(t), sendo M(t) uma distribuição de possibilidade.

No que se refere ao significado de um termo M(t), digamos que este venha representado por um conjunto difuso:

$$\mu_t: U \rightarrow [0, 1],$$

que, dada a proposição "x é t", associa a cada u de U sua possibilidade, isto é, o grau de compatibilidade entre o termo t aplicado à variável x e que o valor de tal variável seja u. Dito de outra forma, a proposição "x é t" induz uma distribuição de possibilidade π_x igual a M(t) quer dizer:

$$M(t) = \pi_x,$$

o que significa que:

$$\text{Pos } \{x = u\} = \mu_t(u)$$

A função:

$$\pi_x \rightarrow [0, 1],$$

igual a μ_t , e que associa a cada u de U a possibilidade que x tem de tomar o valor u, supondo "x é t", recebe o nome de função de distribuição de possibilidade.

Exemplo:

Suponha que, em um contexto particular:

$$\mu_{\text{jovem}}(x) = \begin{cases} 1, & \text{se } 0 \leq x \leq 20, \\ (1 + ((x - 20)/10)^2)^{-1/2}, & \text{se } x > 20 \end{cases}$$

Então, "João é jovem" significa que:

$$\pi_{\text{idade}}(\text{João}) = \text{jovem e, por exemplo:}$$

$$\text{Pes } \{\text{idade}(\text{João}) = 25\} = \mu_{\text{jovem}}(25) = 0,89$$

Observe-se que neste exemplo temos:

$$X \equiv \text{idade}; T(x) = \{\text{jovem, velho, ...}\};$$

$$U = \{0, 1, 2, 3, 4, \dots, 100\}$$

Raciocínio Aproximado

Vários esquemas de raciocínio podem se apresentar na seguinte forma geral:

regra 1:	$A \rightarrow B$
regra 2:	A'
conclusão:	B'

onde $A \rightarrow B$ expressa uma conexão entre A e B, e A' é uma proposição "próxima" a A. A conclusão B' inferida deve ser então próxima a B. A validade deste tipo de inferência depende do tipo de proximidade entre A e A' , e do tipo de relação entre A e B. Esta generalização contém como caso particular o Modus Ponens e o raciocínio por analogia.

A teoria das possibilidades permite calcular a semelhança entre dois predicados A e A' de um mesmo universo de discurso, dando origem a um filtro semântico, baseando-se na representação de A e A' mediante distribuições de possibilidades. A semelhança de A e A' é avaliada calculando as seguintes medidas:

$$\pi(A, A') = \sup_{s \in S} \min[\mu_A(s), \mu_{A'}(s)]$$

$$N(A, A') = 1 - \pi(A, A') =$$

$$\inf \max[\mu_A(s), 1 - \mu_{A'}(s)], s \in S$$

onde $\pi(A, A')$ pode ser considerado como o grau de interseção de $\pi(A)$ e $\pi(A')$, enquanto: $N(A, A')$ pode ser considerado como o grau de inclusão de $\pi(A')$ em $\pi(A)$.

Quando A e A' são constituídos por conjunções ou disjunções de vários predicados, eles podem ser agregados utilizando por exemplo os operadores \min e \max , respectivamente.

Inferência

Algumas regras de inferência são:

MODUS PONENS

$$\begin{array}{l} \mu(A \rightarrow B) \geq a \\ \mu(A') \geq b \\ \hline \mu(B') \geq \min(a, b) \end{array}$$

MODUS TOLLENS

$$\begin{array}{l} \mu(A \rightarrow B) \geq a \\ \mu(B') \leq b \\ \hline \mu(A') \leq \begin{cases} 1 & \text{se } a + b \geq 1 \\ b & \text{se } a + b < 1 \end{cases} \end{array}$$

Regra Composicional de Inferência

Se R é uma relação difusa de U em V e x é um subconjunto difuso de U, então o subconjunto difuso y de V e induzido por x é denotado por:

$$y = x \circ R$$

e definido por:

$$\mu_y(v) = \max \min[\mu_x(u), \mu_R(u, v)], \quad u \in U$$

Note que quando $R = A \rightarrow B$ e $x = A$, então:

$$y = x \circ (A \rightarrow B) = A \circ (A \rightarrow B) = B$$

que é uma identidade exata. Então a equação (1) pode ser vista como uma extensão do Modus Ponens.

A utilização de conjuntos difusos fornece uma nova forma de trabalho dentro dos problemas lógicos. Desta forma, ela coloca-se como uma terceira opção a ser analisada, ao lado das abordagens probabilística e estatística.

3. COMPARAÇÃO COM A TEORIA DAS PROBABILIDADES

Um esclarecimento fundamental deve ser feito no que concerne em como a imprecisão na teoria dos conjuntos difusos ou teoria das possibilidades difere da imprecisão vista na teoria das probabilidades. Basicamente, a diferença é que a teoria das probabilidades trabalha com a aleatoriedade de eventos futuros, enquanto a teoria das possibilidades se ocupa com a imprecisão de eventos atuais ou passados. Randomicidade diz respeito à incerteza sobre a ocorrência ou não de algum evento, enquanto a imprecisão dos conjuntos difusos refere-se à presença ou não de um objeto em um conjunto que tem limites imprecisos.

Uma declaração tipicamente probabilística é:

"Há 10% de chances que a próxima pessoa a entrar na sala tenha menos de 1,70m de altura".

Uma declaração tipicamente possibilística é:

"Aquele homem é baixo".

A declaração probabilística refere-se a um conjunto preciso de pessoas com menos de 1,70m de altura. A imprecisão neste caso tem a ver com o evento relacionado à próxima pessoa a entrar na sala. A declaração difusa não é imprecisa acerca do evento consi-

derado: é "aquele homem". A imprecisão aqui refere-se à dúvida do conceito de "baixo" em si.

4. APLICAÇÃO DE LÓGICA NEBULOSA OU DIFUSA EM DIAGNÓSTICO MÉDICO

"Sistema Especialista CADIAG-2"

CADIAG-2 (Computer-Assisted Diagnosis-2)

O CADIAG-2 possui a estrutura apresentada na figura 1, e seu funcionamento baseia-se em uma representação difusa dos conhecimentos médicos, uma máquina de inferência e um processo de diagnóstico.

- a) Representação de conhecimentos.
- b) Inferência.
- c) Aquisição de conhecimentos.
- d) Processo de diagnóstico.
- e) Explicação do diagnóstico.
- f) Proposta de outros exames.

a) Representação de Conhecimento

O sistema considera quatro classes de entrada tais como:

- Sintomas, sinais ou resultados de testes (S_j),
- Doenças e diagnósticos (D_j),
- Combinações intermediárias (IC_k),
- Combinações de sintomas (SC_l).

Os sintomas S_j têm valores μ_{S_j} no intervalo $[0, 1] \cup \{v\}$


onde:

μ_{S_j} indica o grau com que o paciente apresenta o sintoma S_j ;

$\mu_{S_j} = v$, indica que o sintoma não está presente (não observado).

Por exemplo considerando quantidade de potássio podemos ter:

Baixa	—————→	$\mu_S = 0.0$
Normal	—————→	$\mu_S = 0.4$
Elevada	—————→	$\mu_S = 0.6$
Muito Elevada	—————→	$\mu_S = 0.9$



Também são definidas relações entre as entradas, tais como:

- Sintoma-Doença (S_i, D_j)
- Combinação de Sintomas-Doença ($SC_i D_j$)
- Sintoma-Sintoma ($S_i S_j$)
- Doença-Doença (D_i, D_j)

Estas relações são caracterizadas pelos parâmetros:

- frequência de ocorrência (o);
- grau de confirmação (c)

Para uma relação entre X e Y onde X e Y podem ser qualquer classe de entrada das definidas, a frequência de ocorrência descreve a frequência com a qual X ocorre se Y está presente. Similarmente, o grau de confirmação define com que grau a presença de X implica a presença de Y . Com isto, define-se μ_o e μ_c para valores numéricos e L_o e L_c para valores lingüísticos obtidos através de regras do tipo:

SE (antecedente) ENTÃO (consequência) com (o, c)

Exemplo: $L_o = \text{Sempre} \Rightarrow \mu_o = 1$ ou

$L_c = \text{quase nunca} \Rightarrow \mu_c = 0,01$

Uma relação nebulosa entre o sintoma S_j e o paciente P_q é definida por:

$$\mu_{R_{PS}}(P_q, S_i) = \mu_{S_i}$$

representa o grau com que o sintoma S_j está presente no paciente P_q .

No caso de doença e diagnóstico, define-se

$$0 < \mu_{D_j} < 1$$

onde:

$\mu_{D_j} = 1$ implica um diagnóstico possível e,

$\mu_{D_j} = 0$ implica em diagnóstico confirmado como impossível.

Relações entre doença e paciente, representando o grau que o paciente P_q apresenta a doença D_j por:

$$\mu_{R_{PD}}(P_q, D_j) = \mu_{D_j}$$

Com isto, é possível definir relações de lógica nebulosa e regras de inferência (composição) que permitam inferir um diagnóstico de doença D_j no paciente P_q que apresenta os sintomas S_i .

b) Inferência

Três regras de inferência são utilizadas para deduzir a doença D_j do paciente P_q com sintomas S_i . São elas:

1 - HIPÓTESE E CONFIRMAÇÃO:

$$R_{PD}^1 = R_{PS} \circ R_{SD}^c$$

definida por:

$$\mu_{R_{PD}^1}(P_q, D_j) = \max_{S_i} \min [\mu_{R_{PS}}(P_q, S_i);$$

$$\mu_{R_{SD}^c}(S_i, D_j)]$$

2 - EXCLUSÃO POR PRESENÇA DE SINTOMA:

$$R_{PD}^2 = R_{PS} \circ (1 - R_{SD}^c)$$

definida por:

$$\mu_{R_{PD}^2}(P_q, D_j) = \max_{S_i} \min [\mu_{R_{PS}}(P_q, S_i);$$

$$1 - \mu_{R_{SD}^c}(S_i, D_j)]$$

3 - EXCLUSÃO POR AUSÊNCIA DE SINTOMA:

$$R_{PD}^3 = (1 - R_{PS}) \circ R_{SD}^o$$

definida por:

$$\mu_{R_{PD}^3}(P_q, D_j) = \max_{S_i} \min [1 - \mu_{R_{PS}}(P_q, S_i);$$

$$\mu_{R_{SD}^o}(S_i, D_j)]$$

CONFIRMAÇÃO DO DIAGNÓSTICO:

O diagnóstico é confirmado se:

$$\mu_{R_{PD}^1}(P_q, D_j) = 1.00$$

O diagnóstico é possível se:

$$e < \mu_{R_{PD}^1}(P_q, D_j) < 0.99$$

O "e" é um valor heurístico que permite obter diagnósticos de muito baixa evidência (por exemplo $e = 0.10$).

EXCLUSÃO DO DIAGNÓSTICO

O diagnóstico é excluído se:

$$\mu_{R_{PD}^2}(P_q, D_j) = 1.0 \text{ ou } \mu_{R_{PD}^3}(P_q, D_j) = 1.0$$

Outras relações para inferência são deduzidas similarmente como:

★ Inferência de sintoma combinado - doença:

$$(R_{PD}^i \text{ com } i = 4, 5, 6);$$

★ Inferência sintoma-sintoma:

$$(R_{PD}^i \text{ com } i = 7, 8, 9); e$$

★ Inferência doença-doença:

$$(R_{PD}^i \text{ com } i = 10, 11, 12).$$

$$\mu_{D_j} = 0.0 \text{ se } \begin{cases} \mu_{R_{PD}^2} (P_q, D_j) = 1.0 & \text{ou} \\ \mu_{R_{PD}^3} (P_q, D_j) = 1.0 & \text{ou} \\ \mu_{R_{PD}^5} (P_q, D_j) = 1.0 & \text{ou} \\ \mu_{R_{PD}^6} (P_q, D_j) = 1.0 \end{cases}$$

c) Aquisição de Conhecimentos Médicos

O sistema de aquisição de conhecimento pode adquirir informação de dados médicos e relações deles, armazenando as relações como valores numéricos no intervalo [0,1]. A informação médica pode ser adquirida de duas maneiras:

- Avaliação lingüística ou numérica efetuada por especialistas;
- Avaliação estatística de uma base de dados contendo dados médicos de pacientes com diagnóstico confirmado.

O sistema pode também definir parâmetros tais como freqüência de ocorrência (o), e o grau de confirmação do dado (c). As relações estatisticamente condicionadas de freqüência de ocorrência μ_o e grau de confirmação μ_c são definidas por:

$$\mu_o = \frac{F(S_i \cap D_j)}{F(D_j)} = F(S_i/D_j)$$

$$\mu_c = \frac{F(S_i \cap D_j)}{F(S_i)} = F(D_j/S_i)$$

Relações doença-doença, então, permitirão a inferência de outras confirmações ou exclusões de diagnóstico:

$$\mu_{D_j} = \begin{cases} 1.0 \text{ se } \mu_{R_{PD}^{10}} (P_q, D_j) = 1.0 \\ 0.0 \text{ se } \mu_{R_{PD}^{11}} (P_q, D_j) = 1.0 \\ 0.0 \text{ se } \mu_{R_{PD}^{12}} (P_q, D_j) = 1.0 \end{cases}$$

4 - DIAGNÓSTICOS POSSÍVEIS

O diagnóstico é possível se

$$0 \leq \mu_{D_j} \leq 0.99$$

obtido por:

$$\mu_{D_j} = \max [\mu_{R_{PD}^1} (P_q, D_j), \mu_{R_{PD}^4} (P_q, D_j),$$

$$\mu_{R_{PD}^{10}} (P_q, D_j)]$$

d) Processo de Diagnóstico

1 - ENTRADA DE SINTOMAS

Os sintomas podem ser introduzidos no CADIAG-2 das seguintes formas:

- Por linguagem natural do sintoma S_j ; (febre alta);
- Por base de dados do paciente passando através de um interpretador difuso;
- Por linguagem natural, preenchendo sub-menus do CADIAG-2.

Logo que coletados os sintomas, faz-se uma revisão da lista dos sintomas para inferir relações sintoma-sintoma e combinações de sintomas.

2 - CONFIRMAÇÃO DE DIAGNÓSTICO

O diagnóstico é confirmado para doença D_j no paciente P_q com:

$$U_{D_j} = 1.0 \text{ se } \begin{cases} \mu_{R_{PD}^1} (P_q, D_j) = 1.0 \\ \mu_{R_{PD}^4} (P_q, D_j) = 1.0 \end{cases} \text{ ou}$$

3 - EXCLUSÃO DE DIAGNÓSTICO

O valor difuso $\mu_{D_j} = 0.0$ impossibilita a doença D_j em P_q :

$$\text{se } \begin{cases} 0 \leq \mu_{R_{PD}^1} (P_q, D_j) \leq 0.99 & \text{e/ou} \\ 0 \leq \mu_{R_{PD}^4} (P_q, D_j) \leq 0.99 & \text{e/ou} \\ 0 \leq \mu_{R_{PD}^{10}} (P_q, D_j) \leq 0.99 \end{cases}$$

Outras características importantes do CADIAG-2 são:

e) Explicação do Diagnóstico

A aceitação pelo fisiologista do diagnóstico feito pelo CADIAG dependerá da explicação que ele dê sobre a informação que o levou a este resultado.

f) Proposta de Outros Exames no Paciente

Uma característica importante do CADIAG é a de permitir consultas iterativas, iniciando com dados básicos do paciente e solicitando outros para confirmar o diagnóstico.

5. CONCLUSÃO

A Teoria dos Conjuntos Difusos oferece uma alternativa à Teoria Clássica, que se torna especialmente interessante quando se trata com temas em que predominam conceitos, em lugar de definições. Tal situação está presente em quase todos os campos da atividade humana, já que o processo de tomada de decisões é uma constante e é dependente de um conjunto de elementos, os quais, em geral, não são bem definidos.

REFERÊNCIAS BIBLIOGRÁFICAS

- (1). CUEVA, J. y otros, "Inteligencia Artificial", Série Alianza Informatica, Editora Alianza S.A., Madrid, España, 1986.
- (2). PRADE, H. & DUBOIS, D. "Fuzzy Sets and Systems - Theory and Applications", Academic Press, New York, USA, 1980.

- (3). MAIERS, J. & SHERIF, Y.S. "Applications of Fuzzy Set Theory", IEEE Trans. Syst., Man, Cybern., Vol. SMC-15, Jan. 1985, pp 175-189.
- (4). ZADEH, L.A. "Outline of a New Approach to the Analysis of Complex systems and Decision Processes", IEEE Trans. Syst., Man, Cybern., vol. SMC-3, Jan. 1973, pp 28-44.
- (5). ———, "Fuzzy sets". Information a Control, vol. 8, pp 338-353, 1965.
- (6). ———, "A Fuzzy-algorithmic approach to the definition of complex or imprecise concepts", Systems theory in the social sciences, N. Muller, Eds. Stuttgart, 1976, pp 202-282.
- (7). SANCHEZ, E. "Medical diagnosis and composite fuzzy relations", Advances in fuzzy set theory and application, M. M. Gupta, R. R. Yager, Eds., New York, 1979, pp 437-444.
- (8). Klaus-Peter Adlassnig, "Fuzzy Set Theory in Medical Diagnosis", IEEE Trans. SMC, Vol 16, n. 2, Mar/Apr. 1986.

239686

ATEROSCLEROSE: A PRINCIPAL CAUSA DE MORTE NO MUNDO OCIDENTAL

Antonia Leila Neves Sanches ★
Iran Martin Sanches Júnior ★ ★

RESUMO

Os autores abordam esta complexa doença que resulta da interação de diferentes agentes causais, a qual vem assumindo, a cada década, maior importância na área médica, com inúmeros estudos, pesquisas e publicações em todo o mundo. A importância da Aterosclerose - AS - advém de suas conseqüências ou complicações, como a doença coronariana e o acidente vascular cerebral. A AS é a principal causa de morte no mundo ocidental com proporções epidêmicas alarmantes nas sociedades economicamente desenvolvidas. O conhecimento dos fatores de risco envolvidos e de sua gravidade variável entre as nações, indivíduos e grupos sociais e étnicos representa uma evidência de que a AS não é resultado inevitável da vida, mas um processo que pode ser prevenido.

ABSTRACT

The authors approach this complex disease that results from the interaction of many different causative agents, wich each decade has been assuming a major importance in the medical field, with countless studies, researches and publications all over the world. The importance of the atherosclerosis comes from its consequences or complications as coronary heart disease and cerebral vascular disease. Atherosclerosis is the main cause of death in the western world, with epidemic and alarming propor-

tions in the economically advanced societies. The knowledge of risk factors involved and its variable gravity among the nations, individuals and social and ethnic groups proves that the atherosclerosis isn't an inevitable outcome of life, but a process that can be avoided.

INTRODUÇÃO

1. Definição

A TEROSCLEROSE é um tipo de arteriosclerose, que engloba três variantes morfológicas (aterosclerose, arteriolesclerose e calcificação da média de Mönckeberg). Arteriosclerose literalmente significa "endurecimento das artérias", e suas variantes teriam em comum o espessamento e a perda da elasticidade da parede arterial. A aterosclerose (AS) é a forma mais comum e a mais importante de arteriosclerose; é um distúrbio das grandes artérias que é subjacente à maioria das doenças arteriais coronarianas, aneurismas aórticos, doenças arteriais das extremidades inferiores e doenças cérebro-vasculares.

2. Lesão Básica da AS e Manifestações Clínicas

A primeira necrópsia que descreveu o que parece ter sido uma lesão de artéria coronária por AS é atribuída a Leonardo da Vinci. A lesão básica da AS é o ateroma ou placa fibro-gordurosa. A palavra "ateroma" deriva do grego e significa "mingau de aveia", sendo usada deste 1904 quando

★ Antonia Leila Neves Sanches, é médica do Departamento Médico do Centro Federal de Educação Tecnológica do Paraná.

★ ★ Iran Martin Sanches Júnior, é membro do Serviço de Cirurgia Geral, no Hospital Universitário de Londrina - Paraná.