

UNIVERSIDADE FEDERAL DE SANTA CATARINA
PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

DIAGNÓSTICO DE EQUIPAMENTOS
UMA ABORDAGEM DA TEORIA DE CONJUNTOS DIFUSOS

Dissertação submetida à Universidade Federal de Santa Catarina
para a obtenção do grau de Mestre em Engenharia

GILSON BRAVIANO



0.192.261-3

UFSC-BU

Florianópolis, dezembro de 1990

**DIAGNÓSTICO DE EQUIPAMENTOS
UMA ABORDAGEM DA TEORIA DE CONJUNTOS DIFUSOS**

GILSON BRAVIANO

ESTA DISSERTAÇÃO FOI JULGADA ADEQUADA PARA OBTENÇÃO DO TÍTULO DE

MESTRE EM ENGENHARIA

ESPECIALIDADE ENGENHARIA DE PRODUÇÃO

E APROVADA EM SUA FORMA FINAL PELO PROGRAMA DE PÓS-GRADUAÇÃO.



Prof. Ricardo Miranda Barcia, Ph.D. - ORIENTADOR

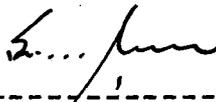


Prof. Sérgio Fernando Mayerle, M. Eng. - CO-ORIENTADOR

BANCA EXAMINADORA



Prof. Ricardo Miranda Barcia, Ph.D. - PRESIDENTE



Prof. Sérgio Fernando Mayerle, M. Eng.



Prof. Neri dos Santos, D. Eng.

A meus pais
A minha esposa

A G R A D E C I M E N T O S

Ao professor Sérgio Fernando Mayerle, pela dedicação oferecida no decorrer do trabalho.

Ao professor Ricardo Miranda Barcia, pela orientação

Aos colegas Antônio Carlos da Silva e Ada Lora Hardt, pelas valiosas sugestões oferecidas.

À Teresinha, minha esposa, e à meus pais, Germano e Nair, pelo apoio dado.

À pessoas queridas, como os familiares de minha esposa.

À Waldir de Souza, Aldanei Tavares, Sofia Kredens e José Carlos Kahl, que estiveram presentes em importantes momentos dessa jornada.

Aos amigos e funcionários, que de forma direta e indireta contribuíram para a realização deste trabalho.

À CAPES, pelo auxílio financeiro que me concedeu.

S U M Á R I O

	Pág
RESUMO.....	ix
ABSTRACT - INGLÊS.....	x
RÉSUMÉ - FRANCÊS.....	xi
LISTA DE FIGURAS.....	xii
LISTA DE QUADROS.....	xiii

CAPÍTULO I

1. INTRODUÇÃO.....	1
1.1 - Origem e importância do trabalho.....	1
1.2 - Objetivo do trabalho.....	3
1.3 - Limitações do trabalho.....	4
1.4 - Estrutura do trabalho.....	4

CAPÍTULO II

2. REVISÃO DA TEORIA DOS CONJUNTOS DIFUSOS.....	5
2.1 - Introdução.....	5
2.2 - Breve histórico da teoria dos conjuntos difusos e sua importância.....	6
2.3 - Definições básicas.....	6
2.3.1 - Funções de pertinência, conjuntos difusos e representações.....	7
2.3.2 - Suporte, conjunto difuso normalizado, con junto difuso vazio e altura.....	8
2.3.3 - União, intersecção e complementar de con juntos difusos.....	9
2.3.4 - Conjunto difuso de nível α , convexidade e número difuso.....	11

2.4 - Definições complementares.....	12
2.4.1 - Medida difusa.....	12
2.4.2 - Medida de probabilidade.....	13
2.4.3 - Medida de possibilidade.....	13
2.4.4 - Medida de difusão.....	13
2.5 - Estimacão de funções de pertinência.....	15
2.5.1 - Método da exemplificacão.....	15
2.6 - Conclusão.....	16

CAPÍTULO III

3. DESCRIÇÃO DO PROBLEMA E REVISÃO BIBLIOGRÁFICA.....	17
3.1 - Introdução.....	17
3.2 - Descrição do problema.....	17
3.2.1 - O que é diagnóstico.....	17
3.2.2 - Para que serve diagnóstico.....	17
3.3 - Modelos fornecedores de diagnóstico.....	18
3.3.1 - Redes neurais.....	18
3.3.2 - Fatos e regras.....	20
3.3.3 - Diagnóstico difuso.....	21
3.4 - Comentários.....	22

CAPÍTULO IV

4. MODELO E TÉCNICA DE SOLUÇÃO PROPOSTOS.....	23
4.1 - Introdução.....	23
4.2 - Descrição do modelo proposto.....	23
4.2.1 - Obtenção das probabilidades dos estados difusos.....	24
4.2.2 - Obtenção das probabilidades dos estados não difusos.....	27
4.2.2.1 - Entropia.....	27
4.2.2.2 - O modelo matemático fornecedor das probabilidades dos estados não difusos.....	29
4.2.2.3 - Obtenção dos relatos difusos.....	29

4.2.3 - Visão "macro" do modelo.....	32
4.3 - Técnica de solução proposta.....	33
4.3.1 - Obtenção do diagnóstico difuso.....	33
4.3.2 - Cálculo das probabilidades dos estados não difusos.....	33
4.4 - Coleta de informações.....	35
4.4.1 - Transformação dos relatos difusos em valores numéricos.....	35
4.4.2 - Obtenção de valores numéricos associados à informações qualitativas.....	38
4.5 - Conclusões.....	41

CAPITULO V

5. DESENVOLVIMENTO DE UM EXEMPLO NUMÉRICO.....	42
5.1 - Introdução.....	42
5.2 - Obtenção dos valores numéricos associados às informações qualitativas.....	42
5.3 - Obtenção dos possíveis defeitos relacionados ao equipamento em estudo.....	44
5.4 - Obtenção dos relatos difusos.....	45
5.4.1 - Obtenção do intervalo probabilístico de cada relato.....	45
5.4.2 - Obtenção do grau de pertinência de cada estado não difuso a cada relato difuso.....	46
5.5 - Formação e resolução do modelo entrópico.....	47
5.6 - Fornecimento do diagnóstico difuso.....	49
5.7 - Comentários.....	52

CAPÍTULO VI

6. CONCLUSÕES E RECOMENDAÇÕES.....	53
------------------------------------	----

BIBLIOGRAFIA.....	55
-------------------	----

APÊNDICE.....	57
---------------	----

R E S U M O

Este trabalho desenvolve um método para obtenção do diagnóstico de equipamentos, utilizando, para isso, o princípio da máxima entropia e a regra de decisão de Bayes, extendida para o caso difuso.

Descreve-se detalhadamente o modelo fornecedor do diagnóstico difuso e propõe-se uma técnica de solução para este.

Desenvolve-se também, um sistema que coleta informações qualitativas e as transformam em valores numéricos que farão parte do banco de dados do modelo.

A B S T R A C T

In this work the Maximum Entropy Principle and the Bayes Decision Rule are extended by means of fuzzy set theory and used for equipment evaluation.

The proposed model for making equipment fuzzy evaluation is extensively described as well as the techniques used for its solution.

A system which allows to gather qualitative informations and transform it in quantitative ones is presented too.

R É S U M É

Dans ce travail, c'est développé une méthode pour l'obtention du diagnostic d'équipements. Pour ça, il a été utilisé le principe de l'entropie maximum et la règle de décision de Bayes, étendue pour le cas difus.

Le modèle fournisseur du diagnostic difus est décrit en details et on y propose une technique de solution.

Dans ce travail, c'est développé aussi un système de recueil d'informations qualitatives que les transformme en valeurs numériques qui feront partie du "date base" du modèle.

LISTA DE FIGURAS

FIGURA 1 - Neurônio formal das redes convencionais.....	20
FIGURA 2 - Gráfico de $H(x,1-x)$	28
FIGURA 3 - Visão "macro" do modelo.....	32
FIGURA 4 - Visão "macro" dos passos para a transformação de informações qualitativas em valores numéricos.....	36

LISTA DE QUADROS

QUADRO 1 - Valores probabilísticos associados à expressões qualitativas.....	43
QUADRO 2 - Intervalo probabilístico associado a eventos.....	44
QUADRO 3 - Limite inferior e superior de cada relato.....	46
QUADRO 4 - Grau de pertinência de cada estado não difuso a cada relato difuso.....	47
QUADRO 5 - Probabilidade de cada estado não difuso.....	48
QUADRO 6 - Grau de pertinência de cada estado não difuso a cada estado difuso.....	49
QUADRO 7 - Probabilidade de cada observação em cada estado.....	50

CAPÍTULO I

1. INTRODUÇÃO

1.1 - ORIGEM E IMPORTANCIA DO TRABALHO

Em problemas de tomada de decisão, quando deseja-se avaliar um *sistema*, normalmente necessita-se de *parâmetros* que auxiliem no processo de avaliação.

O *sistema*, citado acima, pode ser tanto um paciente fazendo uma consulta médica, como uma motobomba que faz parte dos equipamentos responsáveis pelo abastecimento de água de uma cidade.

Tanto o médico, como o responsável pela manutenção da motobomba, precisam de *parâmetros* para avaliar o *sistema* em questão. No caso, o médico observará se o paciente tem febre, tosse, diarreia, vômitos ou pressão alta e utilizará estes *parâmetros* para fornecer um diagnóstico sobre o citado paciente. Já o responsável pela manutenção da motobomba, observará o nível de vibração desta, o estado de conservação do eixo, o alinhamento do equipamento, entre outros fatores, para que possa no final do processo de avaliação ter um diagnóstico sobre a motobomba que avaliou.

Os *parâmetros* que são utilizados neste processo chamam-se estados, e a cada um destes estados pode-se ter vários valores associados, por exemplo: ao perceber que o paciente tem diarreia, o médico questiona-o sobre o fato e o enquadra em alguma situação como: possui frequentemente diarreia, esta começou há três dias, desde 5 anos tem este problema, etc. Da mesma maneira, o responsável pela avaliação da motobomba, ao perceber irregularidade no nível de vibração da mesma, vai enquadrar este estado em alguma situação mais específica, tal como: nível de vibração: muito alto, alto, baixo ou baixíssimo.

Percebe-se, desta maneira, que cada estado a ser observado pelo tomador de decisão (que pode ser o médico ou o indivíduo

responsável pela manutenção da motobomba) pode assumir vários valores e, é claro, que quanto maior o número de estados, maior será o número de combinações entre os valores que estes estados podem assumir. Na prática, nem sempre o tomador de decisão tem tempo para avaliar todas as possíveis combinações entre os valores de estado, já que este número pode ser muito grande.

Uma possível saída para este problema de explosão combinatorial é optar-se pela tomada de decisão baseada em outros parâmetros. Pode-se diagnosticar, por exemplo, tanto o paciente que foi fazer uma consulta médica, como um equipamento qualquer de uma empresa (uma motobomba, por exemplo), utilizando os seguintes estados: ótimo, bom, médio, ruim e muito ruim. Desta maneira, o tomador de decisão terá condições de dar o próximo passo em seu problema. O médico, por exemplo, ao verificar o estado de saúde "muito ruim" do paciente, pode decidir pela internação imediata do mesmo, ao passo que a motobomba que foi diagnosticada como em "bom estado" pode receber uma manutenção corretiva no eixo central, para diminuir a vibração.

Percebe-se que ao passar de um conjunto de variáveis de estado, bem definidas, para outro conjunto, com outras variáveis, pode-se estar trabalhando com novos estados, que já não são tão bem definidos, quanto os anteriores; por isso, aproveitando para explorar a potencialidade da teoria de conjuntos difusos, pode-se trabalhar com variáveis de estado difusas. Ganha-se com isso, a possibilidade de adaptar cada diagnóstico, às convicções individuais de cada tomador de decisão.

Diagnósticos são utilizados tanto em problemas de produto, como em problemas de tomada de decisão no mercado de ações. A área médica, também utiliza constantemente decisões tomadas, a partir de um prévio diagnóstico de cada paciente, no entanto, é no problema de substituição e manutenção de equipamentos, que a aplicação de um diagnóstico conclusivo, permite que as empresas obtenham uma política ótima de manutenção e substituição, no intento de aumentar a produtividade e acompanhar o crescimento tecnológico, mantendo-se em condições de concorrência com as demais.

1.2 - OBJETIVO DO TRABALHO

Asai et al [02], formularam um método que discrimina estados difusos em um espaço probabilístico, determinando uma regra de decisão que fornece um diagnóstico difuso e minimiza a margem do erro probabilístico.

O modelo busca encontrar o diagnóstico difuso de cada *sistema* que está sendo analisado, utilizando o critério de decisão de Bayes, extendido para o caso difuso. Um dos objetivos deste trabalho, é desenvolver este modelo, direcionando-o ao setor de equipamentos.

Segundo Dubois [06], este modelo necessita de dados probabilísticos, normalmente não conhecidos inicialmente.

Tem-se aí, outro objetivo deste trabalho, que é fornecer ao sistema estes dados, utilizando para isto, o princípio da máxima entropia, sugerido também por Jaynes [07].

Desta forma, o trabalho se divide em várias etapas:

- a. obter de um técnico os estados não difusos pertencentes ao sistema;
- b. obter deste técnico, informações qualitativas (relatos difusos), referentes a estes estados;
- c. usar a teoria dos conjuntos difusos para transformar essas informações em valores numéricos;
- d. com esses valores, utilizar o princípio da máxima entropia, e calcular as probabilidades de ocorrência de cada estado não difuso;
- e. descrever detalhadamente o modelo que visa fornecer o diagnóstico difuso, propondo uma técnica de solução para este.

Utilizar-se-á os cinco itens acima citados, para alcançar os objetivos pré determinados.

1.3 - LIMITAÇÕES DO TRABALHO

Em 1.2, item d, foi citada a utilização do princípio da máxima entropia, para encontrar as probabilidades dos estados não difusos. Neste princípio, os relatos difusos, dados por um técnico, serão modelados por somatórios de componentes lineares, limitados inferiormente e superiormente, não sendo tratados os relatos que devam ser modelados por componentes não lineares.

1.4 - ESTRUTURA DO TRABALHO

O presente trabalho foi dividido em seis capítulos.

Este primeiro, visa apresentar origem, importância, objetivos e suas limitações.

O segundo capítulo, apresenta uma revisão da teoria dos conjuntos difusos, dando ênfase às partes relacionadas com o trabalho.

No capítulo 3, são feitas a descrição do problema e uma revisão de modelos já existentes.

Propõem-se, no quarto capítulo, uma técnica de solução para o sistema, que será amplamente desenvolvido. Propõem-se também um método para coleta de informações, e transformação destas, em valores numéricos que servirão de dados para o sistema.

Ter-se-á então, o capítulo 5, que visa apresentar um exemplo numérico, trazido da realidade de uma empresa, e resolve-lo utilizando as propostas expostas no capítulo 4.

Por fim, são apresentadas no sexto capítulo, as conclusões e recomendações referentes a este trabalho.

CAPÍTULO II

2. REVISÃO DA TEORIA DOS CONJUNTOS DIFUSOS

2.1 - INTRODUÇÃO

Neste capítulo, será feita uma revisão dos tópicos da teoria dos conjuntos difusos, que serão utilizados no trabalho, e que possibilitarão, ao leitor que não conhece o assunto, acompanhar o seu desenvolvimento.

De início, será introduzido o conceito do termo difuso, que possui duas interpretações diferentes, registradas na literatura.

Conforme Zadeh [18], o termo difuso é utilizado em situações nas quais um conjunto A , definido sobre um universo X , não possui limites bem definidos. Um exemplo seria o conjunto de homens altos de uma comunidade. De fato, não existe um limite preciso, e bem definido, que diferencie os homens altos dos de estatura mediana.

Por outro lado, Sugeno [14], propõe a utilização do termo difuso em um contexto radicalmente diferente, onde uma medida difusa é usada para caracterizar a probabilidade ou a possibilidade ou o grau de credibilidade subjetiva que se tem no fato de um elemento x pertencer a um conjunto A . Um exemplo seria a genuidade atribuída a uma obra de arte. Embora o conceito de genuidade seja preciso (verdadeiro ou falso), um grau de credibilidade (medida difusa) poderá ser associado à sentença "a obra de arte é genuína", refletindo a convicção que se tem no fato de, ao se adquirir uma obra de arte, esta pertencer ao conjunto de obras genuínas.

Em ambas interpretações, o termo difuso reflete índices de tendência, designados de forma subjetiva por um indivíduo ou grupo de indivíduos, dependendo ainda do contexto.

2.2 - BREVE HISTÓRICO DA TEORIA DOS CONJUNTOS DIFUSOS E SUA IMPORTÂNCIA

Conforme Dubois [06], a teoria dos conjuntos difusos foi inicializada por Zadeh no início dos anos sessenta. Contudo, o termo "difuso" foi inventado por Menger em 1951, ao utilizar a relação transitiva difusa do máximo produto com uma interpretação probabilística.

A nível semântico, a teoria de Zadeh é mais rigorosamente descrita pelo trabalho de Black sobre incerteza, onde tem-se o antecedente da função de pertinência difusa.

Desde 1965, a teoria em questão teve considerável desenvolvimento através de Zadeh e outros 300 pesquisadores, que iniciaram trabalhos sobre sua aplicação em diversas áreas científicas.

Kaufmann, com suas publicações também teve papel importante dentro da teoria dos conjuntos difusos, assim como Sugeno que propôs a utilização do termo difuso num contexto radicalmente diferente.

Ainda, segundo Dubois [06], nos tempos atuais, não só áreas médicas e biológicas tem um desenvolvido potencial de aplicação desta teoria, mas também áreas distintas como: linguística, psicologia, sociologia, economia, geografia, pesquisa operacional, inteligência artificial, robótica e outras.

Percebe-se que, pelo fato de não ser utilizada a tradicional lógica dual, a solução dos modelos se torna mais informativa, além de permitir a adequação das tendências e interpretações do indivíduo ou grupo que utilizam o modelo.

Conforme Armstrong [03], os japoneses consideram a lógica difusa como a promessa tecnológica para o século XXI, e já a estão aplicando em câmeras fotográficas, sinais de televisão, ar condicionados, metrô e elevadores, entre outros produtos, permitindo com isso, que se possa avaliar de forma mais completa a importância do uso dos conjuntos difusos.

2.3 - DEFINIÇÕES BÁSICAS

Apresenta-se, agora, uma série de definições que serão utilizadas no presente trabalho. Algumas delas não terão uso direto, porém servirão de suporte para que se possa definir termos, operações e medidas difusas.

2.3.1 - FUNÇÃO DE PERTINÊNCIA, CONJUNTOS DIFUSOS E SUAS REPRESENTAÇÕES (ZADEH [17]):

Tem-se a seguir, duas definições de extrema importância para a compreensão e o acompanhamento deste trabalho.

DEFINIÇÃO 1:

Seja X um conjunto clássico de objetos, chamado universo, cujos elementos genéricos são denotados por x . A função de pertinência de um elemento x em um subconjunto clássico $A \subseteq X$ é uma função característica $\mu_A : x \rightarrow \{0,1\}$, tal que:

$$\mu_A(x) = \begin{cases} 1 & \text{sse } x \in A \\ 0 & \text{sse } x \notin A \end{cases} \quad (1)$$

onde $\{0,1\}$ é definido como conjunto de avaliação. Se o conjunto de avaliação for o intervalo real $[0,1]$, então A é um conjunto difuso.

O termo $\mu_A(x)$ representa o grau de pertinência de x em relação a A , onde A é um subconjunto de X que não tem fronteiras bem definidas e pode ser caracterizado através da seguinte notação:

$$A = \left\{ \left(x, \mu_A(x) \right), x \in X \right\} \quad (2)$$

A definição acima comporta as seguintes considerações:

- quanto mais próximo de 1 for $\mu_A(x)$, maior será a pertinência de x em relação ao conjunto difuso A ;
- o conjunto universo X nunca é difuso.

No desenvolvimento da teoria dos conjuntos difusos, diversos autores apresentaram várias alternativas para expressar a representação dos conjuntos difusos. Zadeh [17], em 1972, propôs uma notação bastante conveniente para se representar conjuntos difusos, quando X é definido como um conjunto discreto.

$$A = \mu_A(x_1) / x_1 + \dots + \mu_A(x_n) / x_n = \sum_i^n \mu_A(x_i) / x_i \quad (3)$$

Na expressão acima, os elementos com grau de pertinência nulo podem ser omitidos. Isso permite que a expressão possa ser utilizada para caracterizar conjuntos difusos infinitos com suportes discretos.

Quando X é um conjunto contínuo, o conjunto difuso $A \subseteq X$, poderá ser expresso como:

$$A = \int_X \mu_A(x) / x \quad (4)$$

2.3.2 - SUPORTE, CONJUNTO DIFUSO NORMALIZADO, CONJUNTO DIFUSO VAZIO E ALTURA (ZADEH [17]):

Apresenta-se neste item, quatro definições que servirão como suporte para importantes termos a serem definidos posteriormente, neste mesmo capítulo.

DEFINIÇÃO 2:

Seja A um conjunto difuso, definido em um universo X , então:

i) O suporte de A é um sub-conjunto ordinário de X caracterizado por:

$$\text{Supp } A = \left\{ x \in X \mid \mu_A(x) > 0 \right\} \quad (5)$$

ii) O conjunto A é dito normalizado se, e somente se, $\exists x \in X$ tal que $\mu_A(x) = 1$ e $\forall x \in X$ tem-se

$$0 \leq \mu_A(x) \leq 1 \quad (6)$$

iii) \emptyset é um conjunto vazio, se para qualquer $x \in X$,

$$\mu_{\emptyset}(x) = 0 \quad (7)$$

iv) A altura de um conjunto difuso A é definida por:

$$\text{hgt}(A) = \sup_{x \in X} \mu_A(x) \quad (8)$$

2.3.3 - UNIÃO, INTERSECÇÃO E COMPLEMENTAR DE CONJUNTOS DIFUSOS (ZADEH [17]):

Segue-se um grupo de três definições, onde tem-se a oportunidade de perceber a abrangência da teoria dos conjuntos difusos. São definições a que este trabalho se reportará posteriormente.

DEFINIÇÃO 3:

Sejam A e B conjuntos difusos, definidos em um universo X.
Então:

i) O conjunto união, denotado por $A \cup B$ é definido para qualquer $x \in X$, pela seguinte função de pertinência:

$$\mu_{A \cup B}(x) = \max \left\{ \mu_A(x), \mu_B(x) \right\} \quad (9)$$

ii) O conjunto intersecção, denotado por $A \cap B$, é definido, para qualquer $x \in X$, pela função de pertinência:

$$\mu_{A \cap B}(x) = \min \left\{ \mu_A(x), \mu_B(x) \right\} \quad (10)$$

iii) O complementar \bar{A} de um conjunto difuso é um conjunto difuso, definido pela função de pertinência:

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x) \quad (11)$$

2.3.4 - CONJUNTO DIFUSO DE NÍVEL α , CONVEXIDADE E NÚMERO DIFUSO (ZADEH [17]):

As definições deste item, servirão de suporte para importantes termos que serão definidos nos próximos itens.

DEFINIÇÃO 4:

i) Seja A um conjunto difuso definido sobre o universo X . Seja $\alpha \in [0,1]$. Então o conjunto de nível A_α pode ser definido por:

$$A_\alpha = \left\{ x \in X \mid \mu_A(x) \geq \alpha \right\} \quad (12)$$

ii) Um conjunto difuso é convexo se, e somente se, seus conjuntos de nível α são todos convexos;

ou alternativamente:

um conjunto difuso é convexo se para qualquer $\lambda \in [0,1]$ e para quaisquer x_1 e $x_2 \in X$, tem-se:

$$\mu_A \left[\lambda x_1 + (1 - \lambda) x_2 \right] \geq \min \left\{ \mu_A(x_1), \mu_A(x_2) \right\} \quad (13)$$

iii) Um número difuso é um conjunto difuso convexo normalizado A , definido sobre \mathbb{R} , satisfazendo às seguintes condições:

- $\exists x_0 \in \mathbb{R}$, chamado valor mais provável de A , tal que $\mu_A(x_0) = 1$;
- μ_A é contínua por partes.

2.4 - DEFINIÇÕES COMPLEMENTARES

Serão apresentadas agora, definições relativas às medidas difusas. A maior parte delas utiliza as definições pré apresentadas neste trabalho, no item 2.3. Será apresentado também um índice de difusão baseado no conceito de entropia.

Considere-se para isso, $P(X)$ como o conjunto de todos os subconjuntos de X .

2.4.1 - MEDIDA DIFUSA (DUBOIS [06]):

A definição fornecida a seguir, referente à função "g", que expressa uma avaliação da expressão " $x \in A$ ", é importante para uma compreensão mais ampla e profunda deste trabalho.

DEFINIÇÃO 5:

Seja g uma função de $P(X)$ em $[0,1]$. A função "g" é dita uma medida difusa se, e somente se:

i) $g(\emptyset) = 0; g(X) = 1:$

ii) $\forall A, B \in P(X), \text{ se } A \subseteq B \text{ então } g(A) \leq g(B)$ (g é monotônica);

esta condição pode ser interpretada como:

se $A \subseteq B$ então, dizer que $x \in A$ é "menos certo" que dizer $x \in B$.

iii) se $\forall i \in \mathbb{N}, A_i \in P(X)$ e $(A_i)_i$ é monotônica ($A_1 \subseteq A_2 \subseteq \dots$
 $\dots \subseteq A_n \subseteq \dots$ ou $A_1 \supseteq A_2 \supseteq \dots A_n \supseteq \dots$), então

$$\lim_{i \rightarrow \infty} g(A_i) = g(\lim_{i \rightarrow \infty} A_i) \quad (\text{continuidade})$$

2.4.2 - MEDIDA DE PROBABILIDADE (DUBOIS [06]):

Tem-se abaixo a definição de medida de probabilidade, que é, também, uma medida difusa.

DEFINIÇÃO 6:

MP é uma medida de probabilidade se, e somente se:

i) $\forall A, MP(A) \in [0,1]; MP(X) = 1$:

ii) se $\forall i \in \mathbb{N}, A_i \in MP(X)$ e $\forall i \neq j, A_i \cap A_j = \emptyset$, então

$$MP \left(\bigcup_{i \in \mathbb{N}} A_i \right) = \sum_{i \in \mathbb{N}} MP(A_i)$$

2.4.3 - MEDIDA DE POSSIBILIDADE (ZIMMERMANN [19]):

A definição abaixo serve também para uma compreensão mais ampla e profunda do trabalho.

DEFINIÇÃO 7:

Uma medida de possibilidade é uma função $\Pi: P(X) \rightarrow [0,1]$, com as seguintes propriedades:

i) $\Pi(\emptyset) = 0$;

ii) Se $A \subseteq B$ então $\Pi(A) \leq \Pi(B)$;

iii) $\Pi \left(\bigcup_{i \in I} A_i \right) = \sup_{i \in I} \Pi(A_i)$

2.4.4 - MEDIDA DE DIFUSÃO (ZIMMERMANN [19]):

Medidas de difusão, servem para indicar o grau de difusão de um conjunto.

A definição de medida de difusão servirá de suporte para que seja introduzido o índice de difusão baseado no conceito de entropia, que será apresentado logo a seguir. A noção de o que vem a ser entropia, será fornecida em 4.2.2.1.

DEFINIÇÃO 8:

Uma medida de difusão é uma função $d: P(X) \rightarrow [0, +\infty]$ que satisfaz a:

- i) $d(A) = 0$ se A é um conjunto clássico de X ;
- ii) $d(A)$ assume valor máximo para $\mu_A(x) = 0.5, \forall x \in X$;
- iii) $d(A') \leq d(A)$ se A' é menos difuso que A (possui conjunto suporte menos espalhado), isto é:

$$\mu_{A'}(x) \leq \mu_A(x) \text{ se } \mu_A(x) \leq 0.5 \text{ e}$$

$$\mu_{A'}(x) \geq \mu_A(x) \text{ se } \mu_A(x) \geq 0.5;$$

- iv) $d(A) = d(\bar{A})$.

Alguns autores, sugerem, como medidas de difusão, índices baseados em distâncias, combinações entre certas distâncias (distância linear, distância euclidiana, etc), grau de distinção entre o conjunto e o seu complemento, entre outros.

Apresenta-se a seguir, uma importante medida de difusão: o índice de difusão baseado no conceito de entropia (Zimmermann [19]), que será utilizado no decorrer do trabalho.

A entropia como medida difusa de um conjunto A é definida como:

$$d(A) = H(A) + H(\bar{A}), \text{ onde} \quad (14)$$

$$H(A) = -k \sum_{i=1}^n \mu_A(x_i) \ln(\mu_A(x_i)) \quad (15)$$

onde n é o número de elementos do suporte de A e k é uma constante positiva.

2.5 - ESTIMAÇÃO DE FUNÇÕES DE PERTINÊNCIA

Dubois [06], cita vários métodos para estimar funções de pertinência. Um destes, é o método da exemplificação, que será exposto a seguir.

2.5.1 - Método da exemplificação - (Zadeh, 1972):

Seja U um universo de objetos e A um conjunto difuso em U . A função de pertinência μ_A pode ser estimada através de informações parciais, tal que o valor que μ_A assume é obtido a partir de uma amostragem de U . Nesse caso, a determinação de conjuntos difusos através do método da exemplificação é uma extensão da noção linguística da definição estendida. O problema de estimar a função de pertinência de um conjunto difuso através do conhecimento dos valores de um número finito, de pontos em U , é um problema de abstração.

Um exemplo seria o conjunto de homens altos, onde não se tem um limite de altura bem definido para esse grupo. Esse problema linguístico pode ser representado por níveis numéricos: 1, 0.75, 0.5, 0.25 e 0.

Para obter a função de pertinência $\mu_A(x)$, afirma-se que $x \in A$, e a resposta deverá ser dada em uma das formas:

verdadeiro ----->	1.0
não muito verdadeiro ----->	0.75
talvez sim / talvez não ----->	0.5
não muito falso ----->	0.25
falso ----->	0.0

Este método vem a ser o mais conveniente para uso no presente trabalho, por ser de fácil aplicação, não exigindo uma série de cálculos para obter cada grau de pertinência desejado.

2.6 - CONCLUSÃO

A teoria dos conjuntos difusos tem fundamental importância nos casos em que não é conveniente trabalhar com a lógica dual.

Um mesmo problema, ao ser resolvido por várias pessoas em diferentes realidades, pode fornecer resultados distintos, graças à possibilidade de trabalhar com conjuntos difusos. Isso quer dizer que o problema pode ser adaptado às convicções de cada indivíduo que deseja resolvê-lo.

Neste capítulo foram apresentadas uma série de definições, no entanto, é importante salientar que a amplitude de abrangência da teoria em questão é bem maior, já que está sendo desenvolvida uma nova matemática inteiramente voltada ao trabalho com conjuntos difusos.

CAPITULO III

3. DESCRIÇÃO DO PROBLEMA E REVISÃO BIBLIOGRAFICA

3.1 - INTRODUÇÃO

Neste capítulo, descreve-se o problema abordado, fornecendo rápidas noções sobre o que vem a ser diagnóstico e qual a sua importância. Em seguida, apresenta-se três modelos existentes na literatura, que podem ser usados na busca de um diagnóstico.

Parte-se agora para a abordagem do problema, dando inicialmente ênfase ao termo "diagnóstico".

3.2 - DESCRIÇÃO DO PROBLEMA

3.2.1 - O QUE É DIAGNÓSTICO

Conforme Duarte Filho [05], o processo de estabelecimento de diagnósticos, pode ser considerado como um processo de raciocínio evidencial, ou seja: a partir da descrição de um contexto em questão, por meio de descritores relevantes e seus interrelacionamentos, estabelecer um diagnóstico consiste em colher evidências, obedecendo os interrelacionamentos explicitados. Pode-se então, interpretar diagnóstico como uma conclusão referente a um sistema, obtida a partir da análise de variáveis essenciais ao sistema e da relação entre elas.

3.2.2 - PARA QUE SERVE DIAGNÓSTICO

Na área médica, por exemplo, obtém-se o diagnóstico de pacientes, mesmo antes de saber qual sua doença, para que possa ser decidido, conforme a gravidade do problema, se tal paciente será internado ou fará o tratamento em sua casa.

No setor de equipamentos, o diagnóstico serve como auxiliador na tomada de qualquer decisão referente à sua possível substituição ou manutenção.

Na verdade, diagnósticos são úteis em muitos setores de diversas áreas da sociedade, servindo de apoio à tomada de decisão.

Neste trabalho, visa-se fornecer uma técnica de solução para o modelo desenvolvido por Asai et al [02] que diagnostica de maneira difusa um sistema.

Descreve-se a seguir, três modelos existentes na literatura, que podem ser utilizados no fornecimento de diagnósticos, e em caso particular, no diagnóstico de equipamentos.

Escolheu-se estes três modelos pelo fato de trabalharem de maneira diferente o sistema, visando chegar a um mesmo objetivo: o diagnóstico deste sistema.

3.3 - DESCRIÇÃO DE MODELOS FORNECEDORES DE DIAGNÓSTICO

3.3.1 - REDES NEURAIS

Segundo Kohonen [08], redes neurais são redes paralelas interconectadas por elementos simples, com organização hierárquica, que são usados para interação com objetos do mundo real, como o sistema nervoso biológico.

O propósito inicial de todos os sistemas neurais é centralizar o controle de várias funções biológicas. Quando se fala de computação neural, contudo, usualmente tem-se em mente as funções sensoriais e motoras, bem como algumas classes de processamento interno, sendo todas essas funções mutuamente dependentes.

Conforme Lippmann [09], modelos artificiais de redes neurais (ou simplesmente redes neurais, modelos de processamento de distribuição paralela, ou sistemas neurológicos), tem sido estudados por muitos anos na expectativa de executar uma boa

performance humana no campo da linguagem e reconhecimento de imagem.

Esses modelos, são compostos por elementos computacionais não lineares, que operam paralelamente e estão organizados em regras recorrentes de redes neurais biológicas. Na verdade, modelos artificiais de redes neurais, tentam executar boa performance na intercomunicação de caminhos densos, através de elementos computacionais simples, baseando-se na compreensão do sistema nervoso biológico.

Segundo Tank et al [15], circuitos eletrônicos baseados em modelos neurobiológicos são usados para resolver rapidamente problemas complexos. Essas propriedades computacionais, emergem para a interação coletiva de muitas partes ligadas continuamente em uma rede, baseada na idéia de que os neurônios, ou células nervosas, recebem informações de outros neurônios através de conexões.

Em 1984, descobriu-se que redes deste tipo, podem rapidamente oferecer soluções computacionais boas em problemas de atribuição¹.

Kohonen [08] cita outras aplicações de redes neurais:

- reconhecimento de padrões;
- conhecimento da base de dados por informações estocásticas;
- otimização computacional;
- controle robótico;
- problemas de tomada de decisão.

¹ Os problemas de atribuição, normalmente abordados em pesquisa operacional, são do tipo em que n tarefas devem ser realizadas e existem n agentes capazes de executá-las, sendo que a associação de um agente i a uma tarefa j tem um custo c_{ij} . Deve-se designar um agente para cada tarefa, de forma a minimizar o custo total.

Conforme Balaniuk [04], o que define os modelos de redes neurais convencionais, é a função executada por seus elementos, também chamada de "neurônio formal" da rede, que pode ser representado pela figura 1. Nesta figura, a resposta de um neurônio é uma função limite da somatória de suas entradas ponderadas, num instante de tempo isolado.

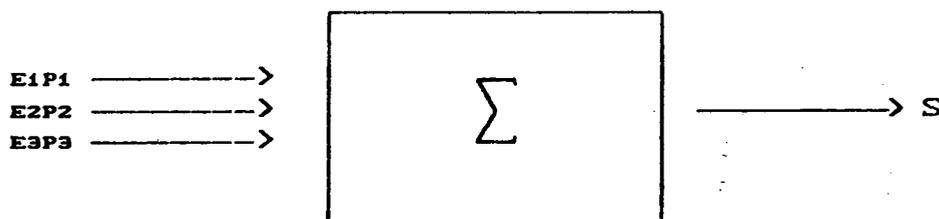


FIGURA 1 - Neurônio formal das redes convencionais

Por função limite, entende-se àquela que responderá positivamente, caso sua entrada exceda um dado valor limite e se omitirá, caso contrário.

Nesse caso, o único comportamento dinâmico da rede será a adaptação dos pesos de suas conexões até chegar a uma configuração, tal que para uma dada entrada, se obtenha a resposta desejada.

Existem vários modelos de redes neurais, e para se resolver um problema, normalmente se adapta tal problema a um destes modelos.

A seguir, tem-se o modelo de fatos e regras, que trata de maneira diferente o mesmo problema de busca de diagnóstico.

3.3.2 - FATOS E REGRAS

Segundo Rich [12], muitas vezes a solução de problemas determinísticos, requer técnicas probabilísticas, porque, a cada passo do processo de solução do problema, não existem informações suficientes disponíveis, que permitam prever o resultado com certeza.

Quando a quantidade de conhecimento contido nas estimativas

probabilísticas cresce, torna-se útil mudar para uma representação baseada em regras. Ao fazê-lo, obtem-se maior flexibilidade na utilização das regras, bem com uma melhor maneira de comunicar a informação entre o sistema e o usuário. É importante que se possa utilizar as informações para formar uma variedade de conclusões, combinando todos os fatos algebricamente.

Precisa-se, no entanto, de um meio para combinar as regras, permitindo que sejam utilizadas conjuntamente. Uma forma de fazer isso é fixando um valor probabilístico associado a cada regra, como mostra o exemplo a seguir:

Se ocorre X

e não ocorre Y

Então,

com probabilidade 0.4, ocorre Z.

Ainda, conforme Rich [12], as regras podem ser combinadas usando métodos fornecidos pela teoria das probabilidades, tais como a fórmula de Bayes, para determinar probabilidades condicionais.

Essas idéias podem ser aplicadas ao problema de diagnóstico, de forma que, através de um conjunto de regras possa-se tirar conclusões a respeito de cada um entre os vários estados que fazem parte do sistema.

Cita-se o MYCIN como um dos sistemas baseados em fatos e regras, que utilizam o raciocínio inexato, exposto de forma sucinta, neste item.

Pôde-se observar que a forma de tratar um mesmo problema, utilizando redes neurais, e o modelo de fatos e regras é diferente. Da mesma maneira, verifica-se a seguir que o modelo de diagnóstico difuso encara sob outro prisma este problema.

3.3.3 - DIAGNÓSTICO DIFUSO

Asai et al [02], propõem que sejam utilizados estados difusos e a regra de decisão de Bayes, extendida também ao caso

difuso, para obter diagnósticos.

De início, observa-se o *sistema* e colhe-se informações que poderão ou não, ser suficientes para fornecer o diagnóstico deste *sistema*.

Utiliza-se o princípio da máxima entropia para verificar o momento em que não é mais necessário colher informações.

Para utilizar este princípio, necessita-se obter uma série de dados. Alguns destes podem ser fornecidos por um técnico que tenha conhecimento em relação ao *sistema*, e outros para que sejam obtidos, necessitam do uso de técnicas de pesquisa operacional.

Este modelo será exposto detalhadamente no capítulo seguinte, para o qual será proposta uma técnica de solução.

3.4 - COMENTARIOS

Três modelos foram descritos sinteticamente, visando fornecer ao leitor uma visão de parte do que há na literatura a respeito de diagnósticos.

Parte-se agora para o detalhamento de um destes modelos, o fornecedor de diagnóstico difuso, no capítulo a seguir.

CAPÍTULO IV

4. MODELO E TÉCNICA DE SOLUÇÃO PROPOSTOS

4.1 - INTRODUÇÃO

Neste capítulo, objetiva-se descrever o modelo desenvolvido por Asai et al [02], propondo, detalhadamente, uma técnica de solução.

Será exposta também, a técnica utilizada para obter informações qualitativas e transforma-las em valores numéricos, que servirão de dados para o modelo citado.

4.2 - DESCRIÇÃO DO MODELO PROPOSTO

Será apresentada neste item, a descrição do modelo fornecido por Asai et al [02], que pode ser utilizado para obter o diagnóstico difuso de equipamentos.

Sejam:

- $S = \{s_1, s_2, \dots, s_n\}$ o conjunto dos estados não difusos;
- $p(s_i)$ a probabilidade de ocorrer o estado s_i ;
- $X = \{x_1, x_2, \dots, x_m\}$ o conjunto de possíveis observações;
- $p(x_i/s_j)$ a probabilidade de observar x_i quando o estado é s_j ;
- $F = \{F_1, F_2, \dots, F_k\}$ o conjunto de estados difusos que realizam

uma partição difusa de S , isto é: $\forall s \in S$, tem-se

$$\sum_{i=1}^k \mu_{F_i}(s) = 1.$$

A discriminação do estado, neste contexto, pode ser feita utilizando a regra de Bayes estendida. Dessa forma, F_i será o estado difuso escolhido se, e somente se

$$P(F_i|X) > P(F_j|X) \quad \text{para } j = 1,2,\dots,k \text{ com } i \neq j. \quad (17)$$

Entende-se com isso, que o estado difuso escolhido será aquele que tiver a maior probabilidade de ocorrência, baseando-se nas observações feitas no sistema em avaliação.

Esta regra corresponde à minimização do erro probabilístico, onde $X = \{x_1, x_2, \dots, x_m\}$ é uma sequência finita de observações independentes.

4.2.1 - OBTENÇÃO DAS PROBABILIDADES DOS ESTADOS DIFUSOS

Para se obter a probabilidade de cada estado difuso associado aos equipamentos em análise, o sistema necessita, inicialmente, de um banco de dados composto pelas seguintes informações:

- $\mu_{F_j}(s_i)$ → grau de pertinência de cada estado não difuso s_i a cada estado difuso F_j , com $i = 1,2,\dots,n$ e $j = 1,2,\dots,k$;
- $p(x_j/s_i)$ → probabilidade de ser observado x_j em cada estado não difuso s_i , com $j = 1,2,\dots,m$ e $i = 1,2,\dots,n$;
- $p(s_i)$ → probabilidade de ocorrência de cada estado não difuso s_i , com $i = 1,2,\dots,n$.

Tanto os $\mu_{F_j}(s_i)$ como as $p(x_j/s_i)$ podem ser fornecidas diretamente por técnicos, mas as $p(s_i)$ nem sempre podem ser

obtidas desta forma. Normalmente, são feitos relatos difusos que envolvem as $p(s_i)$. Segundo Dubois[06], através da modelagem destes relatos, consegue-se obter as probabilidades dos estados não difusos s_i . Este tema será desenvolvido em 4.2.2.

Tendo em mãos os dados citados acima, deve-se fornecer ao sistema, informações referentes às observações x_i , e a cada nova informação, uma série de cálculos devem ser feitos, visando verificar se:

$$H(F/X) > H(S/X) \quad (18)$$

onde $H(S/X)$ representante da incerteza probabilística associada à S pode ser calculada pelo princípio da máxima entropia e $H(F/X)$ que fornece a incerteza dos estados difusos é dado por

$$H(F/X) = - \sum_{i=1}^k p(F_i/X) \cdot \ln(p(F_i/X)) \quad (19)$$

A condição (18), proposta por Asai et al [02], que é aceita e utilizada no desenvolvimento deste trabalho, propõe uma regra de parada na tomada de observações relativas ao sistema. Esta regra depende geralmente da necessidade de precisão da resposta, do custo de cada observação e da limitação do tempo.

Para que se possa calcular (19), é necessário que se tenha o valor de cada $p(F_i/X)$.

Tem-se então, para $i = 1, 2, \dots, k$:

$$p(F_i/X) = \frac{p(X, F_i)}{p(X)} = \frac{\sum_{j=1}^n \mu_{F_i}(s_j) \cdot p(X/s_j) \cdot p(s_j)}{\sum_{i=1}^k p(X/F_i) \cdot p(F_i)} \quad (20)$$

Como, $\mu_{F_i}(s_j)$, $p(s_j)$ e $p(X/s_j)$ são valores que fazem parte do banco de dados, basta que se obtenha $p(X/F_i)$ e $p(F_i)$, os quais podem ser calculados como segue:

$$p(F_i) = \sum_{j=1}^n \mu_{F_i}(s_j) \cdot p(s_j) \quad (21)$$

$$p(X/F_i) = \frac{p(X, F_i)}{p(F_i)} = \frac{\sum_{j=1}^n \mu_{F_i}(s_j) \cdot p(X/s_j) \cdot p(s_j)}{\sum_{j=1}^n \mu_{F_i}(s_j) \cdot p(s_j)} \quad (22)$$

Com estas fórmulas, pode-se calcular (19) e verificar se a condição (18) é satisfeita. Enquanto esta condição não for satisfeita, deve-se partir para uma nova observação, repetindo o ciclo que foi detalhado acima. No caso de ter-se a condição (18) satisfeita, parte-se para a obtenção do diagnóstico difuso, calculando as $p(F_i/X)$ conforme apresentado em (20) e discriminando o estado final conforme (17).

4.2.2 - OBTENÇÃO DAS PROBABILIDADES DOS ESTADOS NÃO DIFUSOS

Para obter a probabilidade de cada estado não difuso, relacionado ao problema de obtenção do diagnóstico difuso de equipamentos, utilizar-se-á o princípio da máxima entropia, trabalhando-se com a obtenção de relatos difusos e sua transformação em equações, que entrarão no modelo matemático como restrições.

Tem-se a seguir, uma breve noção de o que vem a ser entropia, sendo apresentado a seguir, o modelo matemático referente a obtenção das probabilidades dos estados não difusos.

4.2.2.1 - ENTROPIA

Conforme Sivazlian [13], informação é uma palavra comum na linguagem cotidiana, e não é difícil obter um conceito para ela. No entanto, se é pretendido medir uma certa "quantidade de informação", este conceito não continua tão simples.

Segundo Araribóia [01], a idéia de entropia da informação foi inventada por Shannon. O termo "entropia", conforme o contexto em que está sendo usado, pode ser considerado como uma medida de desordem, de incerteza, ou também como uma medida da quantidade de informação que uma pessoa necessita para organizar seus conhecimentos.

Wilson [16], fornece a medida de incerteza desenvolvida por Shannon e Weaver, em 1949:

" Sejam $S = \{s_1, s_2, \dots, s_n\}$ um conjunto finito de eventos e p_i a probabilidade de ocorrência do evento s_i . Considere essas probabilidades não conhecidas. Defini-se a medida de incerteza dada por

$$H(p_1, p_2, \dots, p_n) = -k \sum_{i=1}^n p_i \ln(p_i) \quad , \quad \text{com} \quad \sum_{i=1}^n p_i = 1 \quad (23)$$

onde k é uma constante real, como função entropia."

Ao maximizar H , dado por (23), considera-se a situação de maior incerteza. Isto pode ser observado na figura a seguir, fornecida por Sivazlian [13], que considera:

$$H(p_1, p_2, \dots, p_n) = - \sum p_i \log_2(p_i) \quad (24)$$

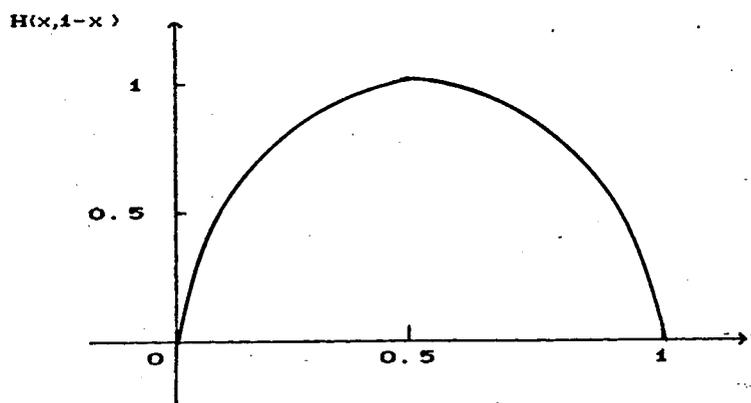


FIGURA 2 - Gráfico de $H(x, 1-x)$

Como a razão entre $\ln(x)$ e $\log_2(x)$ é constante, o fato de estar sendo usado \log_2 ao invés de \ln , aliado ao fato de k ser assumido como 1, não trazem mudanças significativas para este trabalho.

Percebe-se que $H(x, 1-x)$, $0 \leq x \leq 1$ é uma função estritamente côncava.

Assumir $0 \cdot \log_2 0 = 0$ (ou alternativamente $0 \cdot \ln 0 = 0$) é aceitável, mesmo sabendo que $0 \cdot \infty$ é uma indeterminação matemática. Isso pode ser verificado facilmente, partindo da idéia de que $H(0,1) = 0$ (é óbvio que a incerteza entre dois eventos com probabilidades respectivamente iguais a 0 e 1 é nula).

$$H(0,1) = 0 \rightarrow - (1 \cdot \ln 1 + 0 \cdot \ln 0) = 0 \rightarrow - (0 + 0 \cdot \ln 0) = 0 \rightarrow 0 \ln 0 = 0.$$

4.2.2.2 - O MODELO MATEMÁTICO FORNECEDOR DAS PROBABILIDADES DOS ESTADOS NÃO DIFUSOS

Conforme Dubois [06], as probabilidades dos estados não difusos ($p(s_i)$) podem ser calculadas utilizando o princípio da máxima entropia, isto é, serão soluções do problema:

$$\max - \sum_{i=1}^n p(s_i) \ln(p(s_i)) \quad (25)$$

$$\text{s.a.} \quad \alpha_j \leq P(M_j) \leq \beta_j \quad j = 1, 2, \dots, t$$

onde M é um conjunto de relatos difusos. Entende-se por relatos difusos, informações sobre os estados s_i , descritas de forma qualitativa. Cada informação difusa M_i contém a incerteza da idéia do enunciado e também a incerteza de sua ocorrência, que está caracterizada nos limites inferior e superior, (α_i e β_i) de $P(M_i)$

4.2.2.3 - OBTENÇÃO DOS RELATOS DIFUSOS

Conforme Asai et al [02], cada restrição do problema (25) será da forma:

$$\alpha_i \leq P(M_i) = \sum_{j=1}^n \mu_{M_i}(s_j) p(s_j) \leq \beta_i \quad (26)$$

Desenvolvendo (26) para $i = 1, 2, \dots, t$, tem-se:

$$\alpha_1 \leq \mu_{M_1}(s_1) p(s_1) + \mu_{M_1}(s_2) p(s_2) + \dots + \mu_{M_1}(s_n) p(s_n) \leq \beta_1$$

$$\alpha_2 \leq \mu_{M_2}(s_1) p(s_1) + \mu_{M_2}(s_2) p(s_2) + \dots + \mu_{M_2}(s_n) p(s_n) \leq \beta_2$$

$$\vdots \qquad \qquad \qquad \vdots \qquad \qquad \qquad \vdots$$

$$\alpha_t \leq \mu_{M_t}(s_1) p(s_1) + \mu_{M_t}(s_2) p(s_2) + \dots + \mu_{M_t}(s_n) p(s_n) \leq \beta_t$$

(27)

que equivale a:

$$\begin{pmatrix} \alpha_1 \\ \alpha_2 \\ \vdots \\ \alpha_t \end{pmatrix} \leq \begin{pmatrix} \mu_{M_1}(s_1) + \mu_{M_1}(s_2) + \dots + \mu_{M_1}(s_n) \\ \mu_{M_2}(s_1) + \mu_{M_2}(s_2) + \dots + \mu_{M_2}(s_n) \\ \vdots \\ \mu_{M_t}(s_1) + \mu_{M_t}(s_2) + \dots + \mu_{M_t}(s_n) \end{pmatrix} \begin{pmatrix} p(s_1) \\ p(s_2) \\ \vdots \\ p(s_n) \end{pmatrix} \leq \begin{pmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_t \end{pmatrix}$$

(28)

Para simplificar a notação, chamaremos de:

- M a matriz composta pelos graus de pertinência de cada estado não difuso a cada relato difuso;
- α o vetor composto pelos limites inferiores de cada relato difuso.
- β o vetor composto pelos limites superiores de cada relato difuso.
- P o vetor composto pelas probabilidades de ocorrência de cada estado não difuso.

Dessa maneira, (28) ficará:

$$\alpha_{1 \times 1} \leq M_{1 \times n} P_{n \times 1} \leq \beta_{1 \times 1} \quad (29)$$

Os vetores α e β , terão tantas linhas, quantos forem os relatos difusos. O vetor P, terá tantas linhas quantos forem os estados não difusos e a matriz M, por sua vez, terá o número de linhas igual ao número de relatos difusos, e número de colunas igual ao número de estados não difusos.

Convém salientar que $\sum_{i=1}^n p(s_i) = 1$ é também uma restrição do problema (25) já que os eventos s_i são considerados mutuamente exclusivos.

4.2.3 - VISÃO "MACRO" DO MODELO

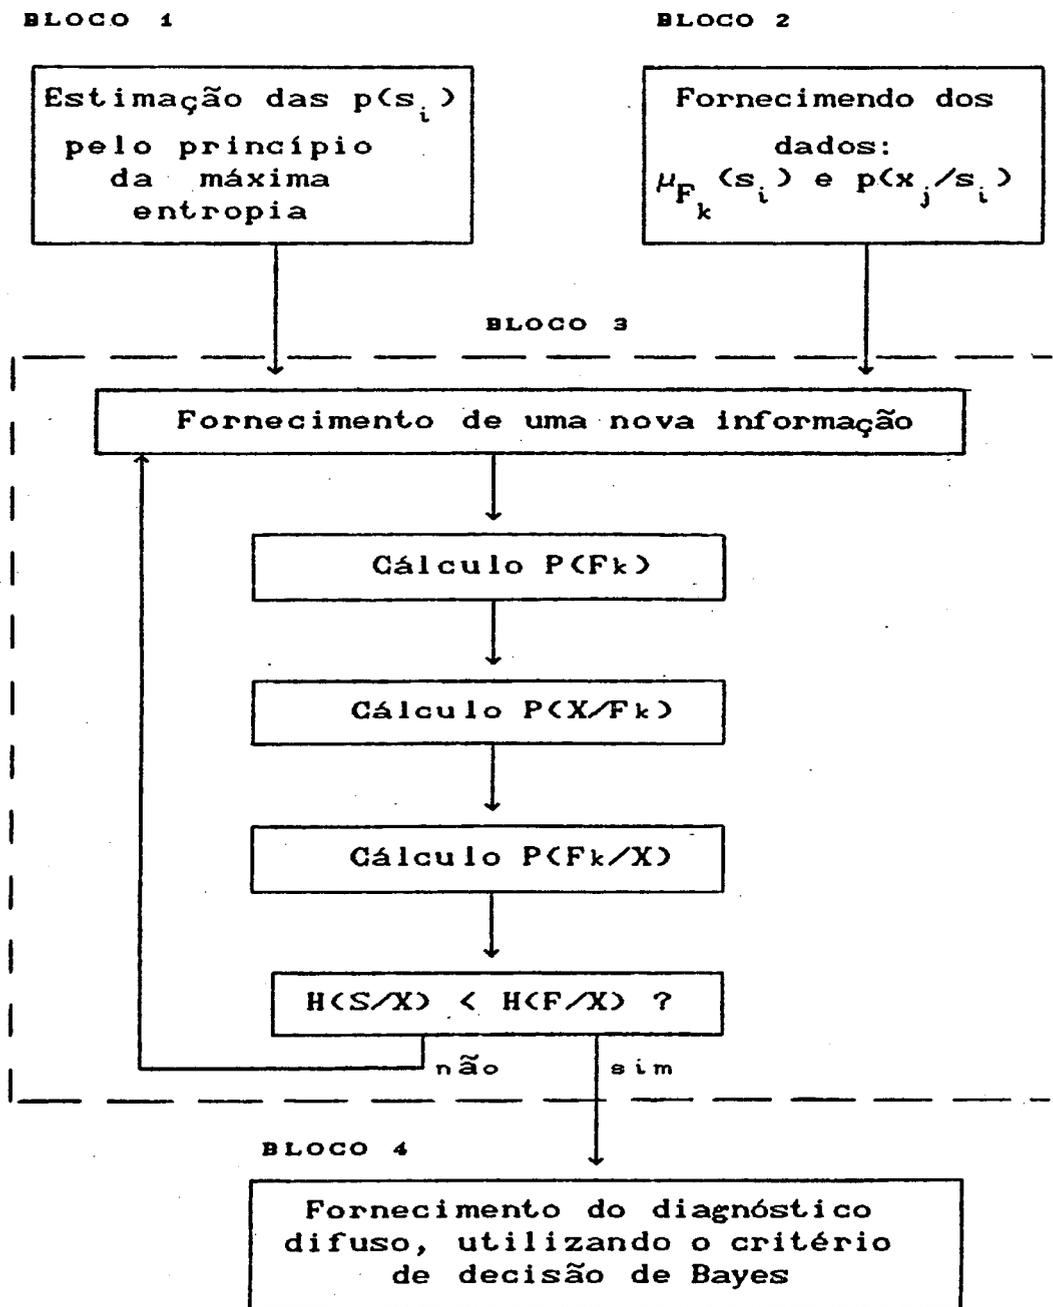


FIGURA 3 - Visão macro do modelo

Esta figura, será utilizada para o melhor entendimento da técnica de solução proposta para este modelo, que será exposta a seguir.

4.3 - TÉCNICA DE SOLUÇÃO PROPOSTA

4.3.1 - OBTENÇÃO DO DIAGNÓSTICO DIFUSO

Para se obter o diagnóstico difuso, conforme a figura 3, deve-se inicialmente ter em mãos os dados referentes aos blocos 1 e 2. Para obter os dados referentes ao bloco 1, usa-se o princípio da máxima entropia, conforme será exposto em 4.3.2; e para obter os dados referentes ao bloco 2, pode-se utilizar a mesma técnica que fornece a matriz M de (29). Esta técnica será exposta em 4.4.1.

Para que possam ser feitos os cálculos referentes ao bloco 3, utiliza-se as fórmulas (19) a (22), fornecendo novas informações, referentes às observações feitas no equipamento em avaliação, até que a condição (18) seja satisfeita. Após isso, parte-se para a determinação do diagnóstico difuso, conforme mostra a figura 3, no bloco 4, utilizando para isso a regra (17) que nada mais é, do que o critério de decisão de Bayes, estendido para o caso difuso.

4.3.2 - CÁLCULO DAS PROBABILIDADES DOS ESTADOS NÃO DIFUSOS

Visando estimar as $p(s_i)$, conforme é especificado no bloco 1 da figura 3, usa-se o princípio da máxima entropia. Em 4.2.2 foi dada a noção de o que vem a ser entropia e foi exposto o problema que deve ser resolvido.

Tendo-se então em mãos (25) e (29), depara-se com uma função não linear que deve ser maximizada, respeitando uma série de restrições lineares.

Para resolver este problema, decidiu-se utilizar o método das penalidades, no qual, uma penalidade é adicionada à função objetivo, por qualquer violação das suas restrições, gerando assim uma sequência de pontos inviáveis, cujo limite é a solução ótima do problema original.

Reescreve-se o problema (25) da seguinte maneira:

$$\begin{aligned} \min \quad & - H \\ \text{s.a.} \quad & h_i(x) = 0 \\ & g_j(x) < 0 \end{aligned} \quad (30)$$

onde a função objetivo torna-se $- H$ por trabalhar-se com minimização, e H é definido por (23), por simplificação.

Adotou-se algumas sugestões oferecidas por Mateus [10], relativas à penalidade que deve ser tomada em cada iteração, durante a resolução do problema, como segue:

$$p(x) = \sum_{i=1}^p r(h_i(x)) + \sum_{k=1}^m s(g_k(x)) \quad (31)$$

onde:

$$\begin{aligned} r(h_i(x)) &= 0 & \text{se} & \quad h_i(x) = 0 \\ r(h_i(x)) &\neq 0 & \text{se} & \quad h_i(x) \neq 0 \end{aligned} \quad (32)$$

$$\begin{aligned} s(g_i(x)) &= 0 & \text{se} & \quad g_i(x) = 0 \\ s(g_i(x)) &> 0 & \text{se} & \quad g_i(x) > 0 \end{aligned} \quad (33)$$

Foi sugerido usar $r(y) = |y|^q$ e $s(y) = [\max\{0, y\}]^q$ onde $q \in \mathbb{Z}_+^*$. No caso em questão, utilizou-se $q = 2$.

Parte-se agora para a exposição da forma utilizada no intento de obter as informações referentes ao sistema em avaliação. Será proposta uma metodologia para transformar essas informações, que normalmente são dadas de maneira qualitativa, em valores numéricos.

4.4 - COLETA DE INFORMAÇÕES

4.4.1 - TRANSFORMAÇÃO DOS RELATOS DIFUSOS EM VALORES NUMÉRICOS

Ao entrevistar um técnico, visando obter informações a respeito do equipamento que deve ser avaliado, deve-se primeiramente, obter a descrição de cada estado não difuso s_i associado ao equipamento (possíveis defeitos, não esquecendo que "sem defeitos" é um estado que deve ser considerado). Após isso, visando resolver o problema (25), deve-se obter do técnico uma série de relatos R_j que envolvam os estados já citados.

Para cada relato, obtem-se as probabilidades mínima e máxima de ocorrência, já que estes, são eventos probabilísticos.

O terceiro passo vem a ser a determinação dos graus de pertinência de cada estado s_i a cada relato R_j . Propõe-se que esses dados sejam obtidos utilizando-se o método da exemplificação, detalhado em 2.5.1.

Tem-se abaixo uma visão sintetizada do que foi exposto.

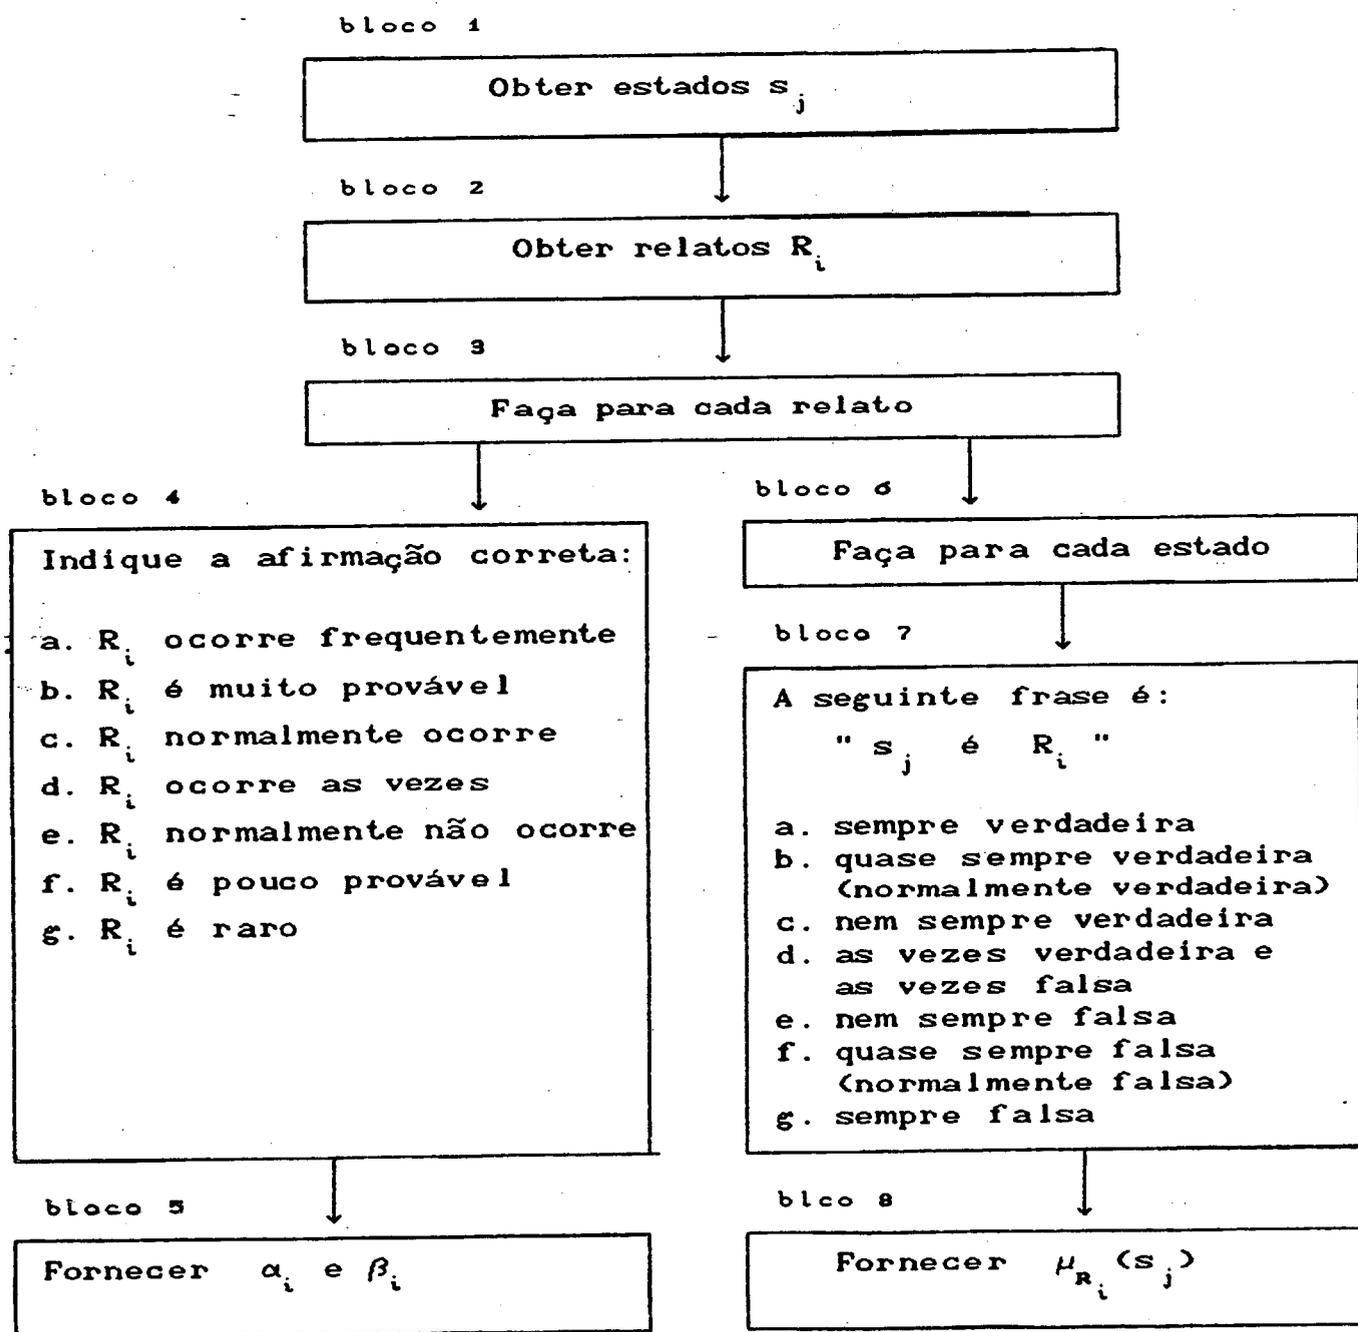


FIGURA 4 - Visão macro dos passos para a transformação de informações qualitativas em valores numéricos

Obtem-se desta forma, tanto os vetores α , β e P como a matriz M , que compõem (29), formando as restrições do problema (19).

Mostra-se a seguir, como podem ser obtidos os vetores associados às possíveis respostas pertencentes ao bloco 4 da figura 4.

Chame-se, por exemplo, de "defeito grave" o relato R_1 . A seguir, obtem-se do técnico, a frequência com que o equipamento em análise apresenta defeitos graves, optando por uma das seguintes alternativas:

- R_1 é frequente
- R_1 é muito provável
- R_1 normalmente ocorre
- R_1 ocorre as vezes
- R_1 normalmente não ocorre
- R_1 é pouco provável
- R_1 é raro

Através dessa informação, obtem-se os limites inferior e superior (α_1 e β_1), da probabilidade de ocorrência de um defeito grave, associado a cada possível resposta.

Caso, "defeitos graves normalmente não ocorram", por exemplo, obtem-se os valores de α_1 e β_1 .

Outra informação que deve ser obtida, é "o quanto cada defeito s_i pode ser considerado um defeito grave". Para isso, deve-se afirmar que, por exemplo, " s_5 é R_1 " (mal alinhamento é um defeito grave), perguntando em seguida, qual alternativa avalia corretamente a afirmação feita, como segue:

A afirmação é:

- sempre verdadeira
- quase sempre verdadeira (normalmente verdadeira)
- nem sempre verdadeira
- as vezes verdadeira e as vezes falsa
- nem sempre falsa
- quase sempre falsa (normalmente falsa)
- sempre falsa.

A cada uma das afirmações acima, está associado um valor numérico ($\mu_{R_1}(s_5)$), conforme o método da exemplificação, apresentado em 2.5.1.

Dependendo do contexto e da necessidade de precisão da resposta, pode-se acrescentar, diminuir ou utilizar outros termos que sirvam de parâmetro de avaliação, associando a cada um, valores numéricos.

4.4.2 - OBTENÇÃO DE VALORES NUMÉRICOS ASSOCIADOS A INFORMAÇÕES QUALITATIVAS

Propoem-se que sejam distribuídos um certo número de questionários, onde cada entrevistado forneça um valor probabilístico mínimo e um máximo para cada uma das expressões a seguir:

um evento

- ocorre frequentemente;
- é muito provável;
- normalmente ocorre;
- ocorre as vezes;
- normalmente não ocorre;
- é pouco provável;
- é raro.

Para obter os limites inferiores e superiores de cada expressão, propõe-se a utilização das regras a seguir:

$$\alpha(\text{expressão } k) = \frac{\sum_{i=1}^n \alpha_i(\text{expressão } k)}{n} \quad (34)$$

$$\beta(\text{expressão } k) = \frac{\sum_{i=1}^n \beta_i(\text{expressão } k)}{n} \quad (35)$$

onde k é cada uma das possíveis expressões, n é o número de questionários utilizados e α_i e β_i são os limites inferiores e superiores fornecido por cada entrevistado, para cada uma das expressões.

No mesmo questionário, cada entrevistado deve colocar em ordem decrescente de credibilidade, as seguintes expressões:

- sempre verdadeira;
- quase sempre verdadeira;
- normalmente verdadeira;
- nem sempre verdadeira e
- as vezes verdadeira e as vezes falsa.

Não é necessário, que sejam colocadas as expressões seguintes, pois elas podem receber valores simétricos aos de suas correspondentes, tendo como ponto de simetria 50 %, como segue:

- a) $p(\text{nem sempre falsa}) = 100 \% - p(\text{nem sempre verdadeira});$
 b) $p(\text{quase sempre falsa}) = 100 \% - p(\text{quase sempre verdadeira});$
 c) $p(\text{normalmente falsa}) = 100 \% - p(\text{normalmente verdadeira})$ e
 d) $p(\text{sempre falsa}) = 100 \% - p(\text{sempre verdadeira}) .$

Para obter o valor probabilístico de cada expressão, associa-se, de início, os seguintes valores:

$$p(\text{sempre verdadeira}) = 100 \% \text{ e}$$

$$p(\text{as vezes verdadeira e as vezes falsa}) = 50 \% .$$

Após o entrevistado fornecer a ordem de credibilidade das expressões fornecidas, pede-se para que forneça também a distância entre as informações sequenciais, pretendendo-se com isso, captar do indivíduo, o quanto cada expressão está bem definida em sua visão pessoal e o quanto ela está diferenciada das outras.

Utiliza-se, para cada questionário, a proporção

$$\frac{50 \%}{T} = \frac{1}{x} \quad (36)$$

onde T é a soma das distâncias fornecidas.

Calcula-se com isso o valor de "x", que representa o valor da unidade de distância, fornecida pelo entrevistado.

Utiliza-se este dado para calcular a probabilidade associada a cada expressão, da seguinte forma:

$$p(2) = p(1) - d(1,2).x = 100 \% - d(1,2).x ;$$

$$p(3) = p(2) - d(2,3).x ;$$

$$p(4) = p(3) - d(3,4).x ;$$

ou genericamente:

$$p(m) = p(m-1) - d(m-1,m).x \text{ para } m = 2,3,4,\dots,b \quad (37)$$

onde b é o número de expressões fornecidas ao entrevistado.

Pode-se perceber que, no caso de ter-se p ímpar, este raciocínio leva a

$$p \left(\frac{b+1}{2} \right) = 50 \% \quad (38)$$

Fazendo o que foi descrito, para cada questionário, o próximo passo, é associar a cada expressão k , um valor numérico final, que pode ser a média entre o valor associado à expressão em cada questionário, como segue:

$$p(\text{expressão } k) = \frac{\sum_{i=1}^n p_i(\text{expressão } k)}{n} \quad (39)$$

4.6 - CONCLUSÃO

Após serem apresentados o modelo, a técnica de solução proposta e uma metodologia para a coleta das informações necessárias ao sistema, conclui-se que, os métodos utilizados para alcançar os objetivos poderiam ter sido outros, dependendo disso, da necessidade de precisão exigida para a resposta.

Conforme Novaes [11], uma das vantagens de se utilizar o método das penalidades é o fato de não ser necessário um ponto inicial viável. Em alguns casos, encontrar este ponto seria tão trabalhoso quanto resolver o problema. Outra vantagem vem a ser o fato de obter-se superfícies de resposta suaves, o que facilita a aplicação dos métodos de busca direta. Apresenta, no entanto, a desvantagem de se ter o ponto ótimo na região não viável, no entanto, na prática, torna-se desprezível a discrepância final.

CAPÍTULO V

5. DESENVOLVIMENTO DE UM EXEMPLO NUMÉRICO

5.1 - INTRODUÇÃO

Neste capítulo, apresenta-se uma aplicação prática do modelo desenvolvido no trabalho, voltada à realidade de uma empresa catarinense, a Companhia de Águas e Saneamento de Santa Catarina - CASAN.

Esta empresa, utiliza para o abastecimento de água no estado, uma série de equipamentos e entre os quais encontram-se as motobombas.

Do bom desempenho das motobombas, dependem hospitais, empresas, residências e todos os setores que recebem água através da CASAN, demonstrando com isso, a importância dos serviços de manutenção e substituição desses equipamentos.

No estado são utilizadas essencialmente, quatro tipos de motobombas. São elas:

- a. motobombas horizontais;
- b. motobombas verticais;
- c. motobombas submersíveis e
- d. motobombas submersas.

O presente capítulo, foi desenvolvido, direcionado às motobombas horizontais, com potência maior ou igual a 30 cv. O modelo desenvolvido neste trabalho poderia ser aplicado também aos outros tipos de motobombas, independente da potência de cada uma.

5.2 - OBTENÇÃO DOS VALORES NUMÉRICOS ASSOCIADOS ÀS INFORMAÇÕES QUALITATIVAS

Foram distribuídos 12 questionários, cujos resultados são apresentados no final deste trabalho, no apêndice.

Procedeu-se como foi exposto em 4.4.2, utilizando (36),

(37) e (39), obtendo-se as seguintes probabilidades associadas a cada expressão:

a. p(sempr e verdadeira)	=	100.00 %
b. p(quase sempre verdadeira)	=	82.04 %
c. p(normalmente verdadeira)	=	81.47 %
d. p(nem sempre verdadeira)	=	58.66 %
e. p(as vezes verdadeira e as vezes falsa)	=	50.00 %
f. p(nem sempre falsa)	=	41.34 %
g. p(normalmente falsa)	=	18.53 %
h. p(quase sempre falsa)	=	17.96 %
i. p(sempr e falsa)	=	0.00 %

Como não houve diferença significativa entre as expressões b e c, ocorrendo o mesmo com as expressões g e h, resolveu-se considera-las como idênticas, assumindo o valor médio entre elas como valor probabilístico. Formou-se assim o quadro 1:

expressões	valor probabilístico
sempre verdadeira	1.0000
quase sempre verdadeira (normalmente verdadeira)	0.8175
nem sempre verdadeira	0.5866
as vezes verdadeira e as vezes falsa	0.5000
nem sempre falsa	0.4134
quase sempre falsa (normalmente falsa)	0.1825
sempre falsa	0.0000

QUADRO 1 - Valores probabilísticos associados à expressões qualitativas

No quadro a seguir, formado de acordo com (34) e (35), é fornecido o intervalo probabilístico relativo a cada evento.

Utilizou-se para isso, as informações obtidas dos entrevistados, conforme dados apresentados no apêndice.

sobre um evento "x"	limite inferior α	limite superior β
é frequente	0.7833	0.9292
é muito provável	0.7425	0.9117
normalmente ocorre	0.6	0.7792
ocorre as vezes	0.2966	0.5667
normalmente não ocorre	0.1342	0.3571
é pouco provável	0.08	0.2208
é raro	0.008	0.085

QUADRO 2 - Intervalo probabilístico associado a eventos

Até o presente momento, nada mais se fez, do que trabalhar com as informações fornecidas pelos entrevistados, visando obter valores que posteriormente se encaixem nos relatos difusos fornecidos por técnicos. Este é na verdade o próximo passo a ser apresentado, como pode-se observar a seguir.

5.3 - OBTENÇÃO DOS POSSÍVEIS DEFEITOS RELACIONADOS AO EQUIPAMENTO EM ESTUDO

Após entrevistar um técnico da CASAN, obteve-se uma lista de 6 possíveis defeitos relacionados às motobombas horizontais com potência maior ou igual a 30 cv. Com isso, foram determinados 7 estados não difusos (ver bloco 1 da figura 4). São eles:

- s_1 = quebra de rolamento;
- s_2 = empeno de eixo;
- s_3 = quebra da bomba;
- s_4 = cavitação;
- s_5 = mal alinhamento;
- s_6 = entrada de ar na sucção;
- s_7 = defeitos irrelevantes.

Após ter-se a relação desses estados não difusos, pretende-se obter a probabilidade de cada um. Para isso, é necessário obter mais informações, de forma que esses estados possam estar interligados. A obtenção dessas informações, chamadas de relatos difusos, será exposta a seguir.

5.4 - OBTENÇÃO DOS RELATOS DIFUSOS

Buscou-se do técnico da CASAN, informações complementares, que relacionassem os defeitos (estados não difusos) citados em 5.3, em grupos. Em retorno, obteve-se 3 grupos de informações, que constituem 3 diferentes relatos (ver bloco 2 da figura 4). Ei-los:

R_1 = defeitos graves;

R_2 = defeitos médios;

R_3 = defeitos simples;

Tendo em mãos esses relatos, busca-se uma associação entre a idéia que cada um transmite e os valores numéricos fornecidos pelo quadro 2, como é descrito a seguir.

5.4.1 - OBTENÇÃO DO INTERVALO PROBABILÍSTICO DE CADA RELATO

Perguntou-se então, sobre a frequência de ocorrência de cada situação (relatos), (ver bloco 4 da figura 4), obtendo-se as seguintes respostas:

- a) defeitos graves normalmente não ocorrem;
- b) defeitos médios ocorrem as vezes;
- c) defeitos simples ocorrem frequentemente.

Com estes resultados, utilizando o quadro 2, foram extraídos os valores α e β associados a cada informação fornecida pelo técnico, (ver bloco 5 da figura 4), como segue:

relato	α	β
defeitos graves	0.1342	0.3571
defeitos médios	0.2966	0.5667
defeitos simples	0.7833	0.9292

QUADRO 3 - Limite inferior e superior de cada relato

Para que se possa encontrar as probabilidades dos estados não difusos, necessita-se ainda de alguns dados, referentes à noção de o quanto cada um dos sete estados está relacionado com cada relato. A obtenção desses dados é exposta a seguir.

5.4.2 - OBTENÇÃO DO GRAU DE PERTINÊNCIA DE CADA ESTADO NÃO DIFUSO A CADA RELATO DIFUSO

Visando verificar o grau de pertinência de cada estado não difuso a cada relato difuso, foi procedido conforme o bloco 7 da figura 5, obtendo-se as seguintes respostas do técnico da CASAN:

	s_1	s_2	s_3	s_4	s_5	s_6	s_7
R_1	b	b	c	f	d	f	g
R_2	f	f	e	d	f	d	g
R_3	g	g	g	e	f	f	a

onde cada letra corresponde a uma expressão, como segue:

- a ----> sempre verdadeira;
- b ----> quase sempre verdadeira (normalmente verdadeira);
- c ----> nem sempre verdadeira;
- d ----> as vezes verdadeira e as vezes falsa;
- e ----> nem sempre falsa;
- f ----> quase sempre falsa (normalmente falsa) e
- g ----> sempre falsa.

Com estas informações, deu-se sequência ao processo, (ver bloco 8 da figura 4), utilizando o quadro 1, e obteve-se a matriz M, formada pelos seguintes graus de pertinência:

	s_1	s_2	s_3	s_4	s_5	s_6	s_7
R_1	0.8175	0.8175	0.5866	0.1825	0.5000	0.1825	0
R_2	0.1825	0.1825	0.4134	0.5000	0.1825	0.5000	0
R_3	0.0000	0.0000	0.0000	0.4134	0.1825	0.1825	1

QUADRO 4 - Grau de pertinência de cada estado não difuso a cada relato difuso

Com base nesta matriz e nos valores de α e β associados à cada relato, pode-se então encontrar a probabilidade de cada um dos 7 estados não difusos. Para isso é utilizado o princípio da máxima entropia.

5.5 - FORMAÇÃO E RESOLUÇÃO DO MODELO ENTRÓPICO

Com os dados obtidos em 5.4.1 e 5.4.2, pode-se formar o problema (25), como segue:

$$\begin{aligned} \text{F.O.: Max} \quad & - p(s_1) \cdot \ln[p(s_1)] - p(s_2) \cdot \ln[p(s_2)] - p(s_3) \cdot \ln[p(s_3)] - \\ & - p(s_4) \cdot \ln[p(s_4)] - p(s_5) \cdot \ln[p(s_5)] - p(s_6) \cdot \ln[p(s_6)] - \\ & - p(s_7) \cdot \ln[p(s_7)] \end{aligned}$$

$$\begin{aligned} \text{s.a.} \quad & 0.1342 \leq 0.8175 p(s_1) + 0.8175 p(s_2) + \\ & + 0.5866 p(s_3) + 0.1825 p(s_4) + \\ & + 0.5000 p(s_5) + 0.5000 p(s_6) \leq 0.3571 \end{aligned}$$

$$0.2966 \leq 0.1825 p(s_1) + 0.1825 p(s_2) + \\ + 0.4134 p(s_3) + 0.5000 p(s_4) + \\ + 0.1825 p(s_5) + 0.5000 p(s_6) \leq 0.5667$$

$$0.7833 \leq 0.4134 p(s_4) + 0.1825 p(s_5) + \\ + 0.1825 p(s_6) + 1.0000 p(s_7) \leq 0.9292$$

$$p(s_1) + p(s_2) + p(s_3) + p(s_4) + p(s_5) + p(s_6) + p(s_7) = 1$$

Pode ser observado que a última restrição deste problema, sempre estará presente no modelo, já que as variáveis que o compõem o modelo (defeitos s_i), são consideradas mutuamente exclusivas.

Resolvendo o problema formado em 5.5, utilizando o método das penalidades, conforme foi descrito em 4.3.2, obteve-se os seguintes resultados:

$p(s_1)$	8.83 %
$p(s_2)$	8.49 %
$p(s_3)$	8.32 %
$p(s_4)$	19.57 %
$p(s_5)$	10.80 %
$p(s_6)$	16.98 %
$p(s_7)$	44.29 %

QUADRO 5 - Probabilidade de cada estado não difuso

Utilizou-se para a resolução deste problema, um micro computador da linha PCxt.

Pode-se observar um destaque na probabilidade do estado 7. Isso deve-se ao alto grau de pertinência deste estado ao relato 3,

que por sua vez foi limitado tanto inferiormente como superiormente por valores altos, em relação aos demais relatos.

Tendo-se em mãos esses dados, o próximo passo do problema é obter o diagnóstico difuso de um equipamento.

5.6 - FORNECIMENTO DO DIAGNÓSTICO DIFUSO

Para que o diagnóstico difuso seja fornecido, é necessário que sejam determinados os estados difusos F_k e que sejam obtidos os graus de pertinência de cada estado não difuso (s_i) à cada estado difuso, através de informações fornecidas pelo técnico entrevistado, ou seja: devem ser obtidos os $\mu_{F_j}(s_i)$.

Discriminou-se então os seguintes estados difusos:

- F_1 = equipamento em bom estado;
- F_2 = equipamento em estado médio e
- F_3 = equipamento ruim.

Ao entrevistar o técnico, obteve-se os seguintes graus de pertinência de cada estado não difuso a cada estado difuso

$\mu_{F_j}(s_i)$:

	s_1	s_2	s_3	s_4	s_5	s_6	s_7
F_1	0.0000	0.0000	0.0000	0.5000	0.5000	0.5000	1
F_2	0.5000	0.1825	0.0000	0.5000	0.0000	0.5000	0
F_3	0.5000	0.8175	1.0000	0.0000	0.5000	0.0000	0

QUADRO 6 - Grau de pertinência de cada estado não difuso s_i a cada estado difuso F_j

Obteve-se ainda do técnico, uma relação das possíveis observações x_i , listadas a seguir:

- x_1 = má lubrificação;
 x_2 = rolamento defeituoso;
 x_3 = vibração anormal;
 x_4 = aquecimento do mancal de rolamento;
 x_5 = desgaste no rotor e/ou no anel do rotor e/ou no anel de desgaste;
 x_6 = nível dinâmico na sucção;
 x_7 = quebra da carcaça da bomba;
 x_8 = ruído anormal;
 x_9 = trepidação na instalação;
 x_{10} = queda de vazão;
 x_{11} = diminuição na área de sucção e
 x_{12} = nada de anormal foi observado.

Finalmente, foram fornecidas as probabilidades de ser observado x_i , dado que o estado é s_j ($p(x_i / s_j)$), como pode ser observado no próximo quadro.

	s_1	s_2	s_3	s_4	s_5	s_6	s_7
x_1	0.3	0.1	0.0	0.0	0.0	0.0	0.0
x_2	0.3	0.2	0.0	0.0	0.1	0.0	0.0
x_3	0.0	0.3	0.0	0.0	0.1	0.0	0.0
x_4	0.1	0.1	0.0	0.0	0.1	0.0	0.0
x_5	0.0	0.1	0.0	0.0	0.1	0.1	0.0
x_6	0.0	0.0	0.0	0.3	0.0	0.2	0.0
x_7	0.0	0.0	0.8	0.0	0.0	0.0	0.1
x_8	0.3	0.0	0.2	0.0	0.2	0.0	0.0
x_9	0.0	0.2	0.0	0.0	0.4	0.0	0.0
x_{10}	0.0	0.0	0.0	0.3	0.0	0.5	0.0
x_{11}	0.0	0.0	0.0	0.4	0.0	0.2	0.0
x_{12}	0.0	0.0	0.0	0.0	0.0	0.0	0.9

QUADRO 7 - Probabilidade de cada observação em cada estado

EXEMPLO 1:

Tendo-se em mãos todos os dados necessários, aplicou-se o modelo à uma motobomba, onde se observou x_2 , ou seja: rolamento defeituoso, obtendo-se $p(F_1) = 9.95\%$, $p(F_2) = 30.11\%$ e $p(F_3) = 59.93\%$. Concluiu-se então que:

$$H(S/x_2) = 1.0349 > H(F/x_2) = 0.8978$$

Observou-se novamente o equipamento, percebendo x_3 , ou seja: vibração anormal. O modelo forneceu então: $p(F_1) = 18.37\%$, $p(F_2) = 31.63\%$ e $p(F_3) = 50\%$. Concluiu-se desta vez que:

$$H(S/x_2 \text{ e } x_3) = 0.4636 < H(F/x_2 \text{ e } x_3) = 1.0219$$

Como $\max_i \left\{ P(F_i/x_2 \text{ e } x_3) \right\} = P(F_3/x_2 \text{ e } x_3)$, considerou-se que o equipamento analisado está no estado F_3 , ou seja: é um equipamento ruim.

EXEMPLO 2:

Apresenta-se a seguir outro exemplo, onde se observa no equipamento apenas x_1 , ou seja: má lubrificação. Verifica-se que $p(F_1) = 0\%$, $p(F_2) = 42.30\%$ e $p(F_3) = 57.70\%$, o que implica em:

$$H(S/x_1) = 0.562 < H(F/x_1) = 0.6812$$

Como $\max \left\{ P(F_i/x_1) \right\} = P(F_3/x_1)$, considerou-se que o equipamento está no estado F_3 , ou seja, é um equipamento ruim.

5.7 - COMENTARIOS

Para obter os valores pertencentes aos quadros 1 e 2, foram utilizados 12 questionários, cujos resultados estão presentes no apêndice.

É interessante ressaltar, que para obter as informações de técnicos, não é necessário que sejam feitas as perguntas em ordem e nos termos que são apresentadas, bastando para isso, que através de um diálogo sobre os equipamentos, o entrevistador vá obtendo as informações necessárias, à medida que o técnico as vai fornecendo qualitativamente e de forma difusa.

Pelo primeiro exemplo, pode-se observar que o diagnóstico difuso da motobomba analisada, foi obtido com apenas duas observações. Esta é a grande vantagem do método, que não exige uma análise total do equipamento. Já no segundo exemplo percebeu-se que apenas uma observação foi suficiente para determinar o estado difuso da motobomba. Conclui-se, portanto, que o modelo é sensível a quantidade e qualidade das informações, e permite que se tenha um diagnóstico a partir de um conjunto parcial dessas informações.

CAPÍTULO VI

6. CONCLUSÕES E RECOMENDAÇÕES

Conclui-se que o modelo fornecedor do diagnóstico difuso, estudado e desenvolvido neste trabalho, tem a vantagem de não exigir inicialmente uma análise total do equipamento em avaliação, bastando normalmente, uma observação parcial, para que se obtenha seu diagnóstico difuso.

Conclui-se também, que os algoritmos utilizados para encontrar as probabilidades dos estados não difusos, relativos aos equipamentos em análise, funcionaram, fornecendo resultados com uma boa precisão.

No que diz respeito à retirada de informações qualitativas de um técnico sobre um determinado equipamento e à transformação dessas informações em valores numéricos, o presente trabalho apresentou uma proposta que desenvolve e expressa tais informações de maneira difusa.

Sugere-se porém, que em futuros estudos, onde este tema seja desenvolvido, trabalhe-se com a transformação dessas informações qualitativas, de maneira que a relação entre as variáveis possa ser também expressa de forma não linear, ou seja, que os eventos não sejam necessariamente mutuamente exclusivos.

Sugere-se, também, que outros métodos (além do método das penalidades e de Hooke e Jeeves, utilizados neste trabalho) sejam implementados, visando otimizar o tempo de resolução computacional e a precisão na solução do modelo fornecedor das probabilidades dos estados não difusos.

Sugere-se ainda, que este modelo, seja ampliado com o acréscimo de informações quantitativas (vida útil estimada, valor residual no final da vida útil, etc), tomando-se o cuidado de não repetir informações previamente fornecidas de forma qualitativa.

Para as empresas que queiram utilizar este modelo, o qual possui grande sensibilidade em relação aos dados, recomenda-se que tenham o cuidado de tomar informações de técnicos

experientes e competentes, já que é destes que surgirão os dados que fornecerão os resultados finais.

Sugere-se que seja feito um estudo, abordando a sequência em que as observações devam ser tomadas, analisando aspectos como custo para obter cada observação, restrições de tempo, observações que forneçam mais informação ao sistema e outros.

Sugere-se finalmente, que este modelo seja ampliado, utilizando técnicas de programação dinâmica, que o transformem em um sistema de apoio a decisão, em problemas de manutenção e substituição de equipamentos.

B I B L I O G R A F I A

01. ARARIBÓIA, G. Inteligência Artificial - Um curso prático, Medindo a entropia. 269/270, 1988.
02. ASAI, K. et al. Kybernetes 6, On discrimination of fuzzy stats in probability space. 185-192, 1977.
03. ARMSTRONG, Larry et al. Business Week - International, why "Fuzzy Logic" beats black-or-white thinking. 81/82, may 21, 1990.
04. BALANIUK, Remis & NAVAUX, Philippe O. Reconhecimento de padroes codificados em sequencias utilizando redes neurais, 6° SBIA - 359-372, 1989.
05. DUARTE Filho, Nelson & FERLIN, Claudia, Raciocinio evidencial e aprendizado automatico com o uso de redes Bayesianas. 6° SBIA, 169-183, 1989.
06. DUBOIS, D. & PRADE, H. Fuzzy set and systems - Theory and applications, Fuzzy Diagnosis. 335-340, 1980.
07. JAYNES, E. T. IEEE - Transactions systems science and cybernetics SSC 4, Prior probabilities. 227-241, 1968.
08. KOHONEN, Teuvo. An introduction to neural computing. Neural networks, vol 1, pp 3-16, 1988.
09. LIPPMANN, Richard P. An introduction to computing with neural nets. IEEE ASSP Magazine, vol 3, n° 4, pp 4-22, april 1987.
10. MATEUS, G. R. & LUNA, H. P. L. Programacao nao linear, BH,1986.
11. NOVAES, A. G. Métodos de otimização - Aplicação aos transportes, SP, 1978.

12. RICH, Elaine. Inteligencia artificial. Trad 1988, pp 202-234.
13. SIVAZLIAN, B. D. Analysis of systems in operations research. 1975.
14. SUGENO, M. Fuzzy measures and integrals: A survey. In gupla et ali. 1977.
15. TANK, David W. & HOPFIELD, John J. Collective computation in neuronlike circuits. SC Amer., december 1987.
16. WILSON A. G. Entropy in urban and regional modelling, 01-14.
17. ZADEH, L. A. Inference control, 8:338-56. Fuzzy sets. 1965.
18. ZADEH, L. A. Journal Cybernetic 3, A fuzzy set theoretic interpretation of linguistic hedges, 04-34, 1972.
19. ZIMMERMANN, H. J. Fuzzy set theory - and its applications. 1985.

APÊNDICE

Questionário fornecido aos entrevistados

I) Coloque em ordem decrescente de credibilidade, os termos a seguir:

- (1) - sempre verdadeira
- () - quase sempre verdadeira
- () - normalmente verdadeira
- () - nem sempre verdadeira
- (5) - as vezes verdadeira e as vezes falsa

II) Usando valores pertencentes ao conjunto dos números naturais, determine a distância entre as informações:

$d(1,2) =$

$d(2,3) =$

$d(3,4) =$

$d(4,5) =$

III) Forneça valores reais, pertencentes ao intervalo $[0,1]$, que transmitam os níveis de probabilidade mínima e máxima, sobre cada expressão abaixo:

o evento "x" :

	mínimo	máximo
- é frequente	[]
- é muito provável	[]
- normalmente ocorre	[]
- ocorre as vezes	[]
- normalmente não ocorre	[]
- é pouco provável	[]
- é raro	[]

Síntese das respostas relativas ao questionárioQuestão I

E1	E2	E3	E4	E5	E6	E7	E8	E9	E10	E11	E12
(1)	(1)	(1)	(1)	(1)	(1)	(1)	(1)	(1)	(1)	(1)	(1)
(2)	(3)	(3)	(2)	(3)	(2)	(2)	(2)	(3)	(2)	(3)	(3)
(3)	(2)	(2)	(3)	(2)	(3)	(3)	(3)	(2)	(3)	(2)	(2)
(4)	(4)	(4)	(4)	(4)	(4)	(4)	(4)	(4)	(4)	(4)	(4)
(5)	(5)	(5)	(5)	(5)	(5)	(5)	(5)	(5)	(5)	(5)	(5)

Questão II

E1	E2	E3	E4	E5	E6	E7	E8	E9	E10	E11	E12
4	4	1	5	1	3	1	2	200	2	2	1
2	1	1	1	1	1	2	4	50	1	1	1
2	3	4	4	1	4	1	6	250	4	2	3
1	2	2	1	1	1	2	3	100	1	1	0

Questão III

E1	E2	E3	E4
[0.8 , 1.0]	[0.90 , 1.00]	[0.8 , 0.9]	[0.75 , 0.90]
[0.7 , 0.9]	[0.81 , 0.89]	[0.7 , 0.8]	[0.65 , 0.80]
[0.6 , 0.7]	[0.60 , 0.70]	[0.5 , 0.8]	[0.65 , 0.80]
[0.3 , 0.5]	[0.16 , 0.30]	[0.2 , 0.7]	[0.40 , 0.55]
[0.0 , 0.2]	[0.06 , 0.10]	[0.4 , 0.6]	[0.20 , 0.35]
[0.0 , 0.1]	[0.11 , 0.15]	[0.3 , 0.5]	[0.10 , 0.25]
[0.0 , 0.1]	[0.00 , 0.05]	[0.0 , 0.1]	[0.00 , 0.10]

E5	E6	E7	E8
[0.9 , 1.0]	[0.8 , 1.0]	[0.80 , 1.00]	[0.60 , 0.70]
[0.8 , 1.0]	[0.7 , 0.9]	[0.70 , 0.90]	[0.70 , 0.75]
[0.7 , 1.0]	[0.7 , 0.8]	[0.40 , 0.60]	[0.45 , 0.55]
[0.5 , 1.0]	[0.2 , 0.8]	[0.20 , 0.40]	[0.30 , 0.35]
[0.1 , 0.5]	[0.2 , 0.6]	[0.10 , 0.20]	[0.45 , 0.55]
[0.1 , 0.3]	[0.1 , 0.3]	[0.05 , 0.15]	[0.10 , 0.15]
[0.0 , 0.1]	[0.0 , 0.2]	[0.00 , 0.05]	[0.01 , 0.05]

E9	E10	E11	E12
[0.85 , 0.95]	[0.80 , 1.00]	[0.9 , 1.0]	[0.5 , 0.7]
[0.95 , 1.00]	[0.90 , 1.00]	[0.5 , 1.0]	[0.8 , 1.0]
[0.80 , 0.90]	[0.80 , 1.00]	[0.4 , 0.8]	[0.5 , 0.7]
[0.40 , 0.50]	[0.40 , 0.60]	[0.2 , 0.6]	[0.3 , 0.5]
[0.10 , 0.20]	[0.00 , 0.20]	[0.0 , 0.4]	[0.0 , 0.1]
[0.00 , 0.05]	[0.00 , 0.20]	[0.0 , 0.2]	[0.1 , 0.3]
[0.00 , 0.02]	[0.00 , 0.05]	[0.0 , 0.2]	[0.0 , 0.1]