

UNIVERSIDADE FEDERAL DE SANTA CATARINA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
ELÉTRICA

**SISTEMA ESPECIALISTA NEBULOSO PARA
DIAGNÓSTICO MÉDICO**

DISSERTAÇÃO SUBMETIDA À UNIVERSIDADE FEDERAL DE
SANTA CATARINA COMO PARTE DOS REQUISITOS PARA
OBTENÇÃO DO GRAU DE MESTRE EM ENGENHARIA
ELÉTRICA

KATHYA SILVIA COLLAZOS LINARES

Florianópolis, fevereiro de 1997

**SISTEMA ESPECIALISTA NEBULOSO PARA
DIAGNÓSTICO MÉDICO**

KATHYA SILVIA COLLAZOS LINARES

**ESTA DISSERTAÇÃO SERÁ JULGADA ADEQUADA PARA
OBTENÇÃO DO TÍTULO DE**

MESTRE EM ENGENHARIA ELÉTRICA

**ÁREA DE CONCENTRAÇÃO EM ENGENHARIA BIOMÉDICA,
E APROVADA EM SUA FORMA FINAL PELO PROGRAMA DE
PÓS-GRADUAÇÃO**

PROF. JORGE MUNIZ BARRETO, D.Sc.A.

Orientador

PROF. ADROALDO RAIZER, D.Sc.

Coordenador da Pós-Graduação Eng. Elétrica

Banca examinadora:

Prof. Jorge Muniz Barreto, D.Sc.A.

Prof. Silvia Modesto Nassar, D. Sc.

Prof. Fernando Mendes de Azevedo, D.Sc.

Prof. Heitor Silverio Lopes, D.Sc.

Aos meus pais Víctor e Rosa.

Agradecimentos

À meu esposo Jorge pela sua paciência.

Sumário

| | |
|---|-----------|
| Sumário | i |
| Lista de Figuras | iv |
| Lista de Tabelas | vi |
| Abreviaturas | vii |
| Resumo | viii |
| Abstract | ix |
| 1 Introdução | 1 |
| 1.1 Justificativas | 2 |
| 1.1.1 Tratamento da incerteza e imprecisão em SE de apoio à decisão em Medicina | 5 |
| 1.2 Objetivos Gerais | 6 |
| 1.3 Objetivos Específicos | 6 |
| 2 Raciocínio Impreciso e Incerto | 8 |
| 2.1 Formas de Raciocínio | 8 |
| 2.1.1 Raciocínio Plausível | 9 |
| 2.1.2 Raciocínio Probabilístico | 15 |
| 2.1.3 Raciocínio Nebuloso | 20 |
| 2.1.4 Raciocínio Qualitativo | 28 |
| 2.2 Avaliação das Formas de Raciocínio | 35 |
| 3 Tratamento da Imprecisão e Incerteza | 37 |
| 3.1 Probabilidades e Teorema de Bayes | 38 |

| | | |
|----------|--|-----------|
| 3.1.1 | Dificuldades com o Método Bayesiano | 39 |
| 3.2 | Fatores de Certeza | 40 |
| 3.2.1 | Avaliando com Fatores de Certeza | 43 |
| 3.2.2 | Dificuldades com os Fatores de Certeza | 46 |
| 3.3 | A Teoria de Dempster-Shafer | 47 |
| 3.3.1 | A Função <i>Mass</i> (m) | 48 |
| 3.3.2 | Combinando evidências | 48 |
| 3.3.3 | Normalização de Crenças | 50 |
| 3.3.4 | Dificuldades com a Teoria de Dempster-Shafer | 51 |
| 3.4 | Métodos Nebulosos | 52 |
| 3.4.1 | Lógica nebulosa e Linguagem natural | 52 |
| 3.4.2 | Representação de Funções Padrões | 54 |
| 3.4.3 | Variáveis Linguísticas | 58 |
| 3.4.4 | Sistemas de Lógica Nebulosa | 59 |
| 3.4.5 | Dificuldades com os Métodos nebulosos | 64 |
| 3.5 | Avaliação dos Métodos | 65 |
| 4 | Raciocínio Clínico e Tomada de Decisão | 67 |
| 4.1 | Métodos de Raciocínio | 68 |
| 4.1.1 | Raciocínio Dedutivo | 68 |
| 4.1.2 | Raciocínio Indutivo | 68 |
| 4.1.3 | Raciocínio Abduativo | 69 |
| 4.1.4 | Raciocínio Causal | 69 |
| 4.2 | As etapas da decisão médica | 69 |
| 4.2.1 | Identificação do problema | 70 |
| 4.2.2 | Estruturação do problema | 70 |
| 4.2.3 | Escolha da solução | 70 |
| 4.3 | Decisão clínica | 71 |
| 4.4 | Incerteza e imprecisão na decisão clínica | 72 |
| 5 | Área de Aplicação : Reumatologia | 74 |
| 5.1 | Conceito | 74 |
| 5.2 | Classificação | 75 |
| 5.3 | Manifestações clínicas | 77 |
| 5.4 | Lupus Eritematoso Sistêmico (LES) | 79 |

| | | |
|----------|--|------------|
| 5.4.1 | Critérios Diagnósticos | 80 |
| 5.4.2 | Patologia | 80 |
| 5.4.3 | Manifestações Clínicas | 81 |
| 5.5 | Artrite Reumatóide (AR) | 81 |
| 5.5.1 | Critérios Diagnósticos | 82 |
| 5.5.2 | Patologia | 83 |
| 5.5.3 | Manifestações Clínicas | 83 |
| 6 | S. E. Nebuloso para Diagnóstico Médico | 85 |
| 6.1 | Raciocínio por analogia | 88 |
| 6.2 | Raciocínio Baseado em Casos e Raciocínio Baseado em Regras | 91 |
| 6.3 | O Ciclo do RBC | 92 |
| 6.4 | O Sistema Especialista para Diagnóstico Médico por Analogia Nebulosa (SEDMAN) | 93 |
| 6.4.1 | Representação do Conhecimento Médico | 96 |
| 6.4.2 | Aquisição do Conhecimento Médico | 96 |
| 6.4.3 | Sistema de Informação Médica | 96 |
| 6.4.4 | Interpretador Nebuloso dos Dados | 97 |
| 6.4.5 | Módulo de Inferência por Analogia Nebulosa | 98 |
| 6.4.6 | Interface com o Usuário | 99 |
| 7 | Discussão e Conclusões | 104 |
| 7.1 | Análise dos resultados | 104 |
| 7.2 | Discussão | 104 |
| 7.3 | Conclusões | 105 |
| 7.4 | Trabalhos Futuros | 106 |
| | Referências Bibliográficas | 108 |

Lista de Figuras

| | | |
|------|--|----|
| 2.1 | Processo indutivo | 11 |
| 2.2 | Processo de generalização | 12 |
| 2.3 | Processo de especialização | 13 |
| 2.4 | Processo de analogia | 14 |
| 2.5 | Grafos direcionados | 19 |
| 2.6 | Função de pertinência | 21 |
| 2.7 | Sistema de lógica nebulosa | 22 |
| 2.8 | Formas de representação de conjuntos nebulosos | 23 |
| 2.9 | Posição da cabina do caminhão em relação a doca | 23 |
| 2.10 | Funções de pertinência para o exemplo do caminhão | 24 |
| 2.11 | Ativação da regra $R^{5,1}$ e as suas saídas | 25 |
| 2.12 | Ativação da regra $R^{5,2}$ e as suas saídas | 25 |
| 2.13 | Ativação da regra $R^{6,2}$ e as suas saídas | 26 |
| 2.14 | Os conjuntos nebulosos obtidos utilizando o t-conorma para as in- ferências: (a) mínimo e (b) produto | 26 |
| 2.15 | (a) λ -corte e (b) α -corte em conjuntos nebulosos | 27 |
| 2.16 | Exemplo para o qual o denebulizador Meio do máximo não faz sentido | 27 |
| 2.17 | Física qualitativa | 29 |
| 2.18 | Espaços quantitativos | 31 |
| 2.19 | Coefficientes de mudança | 31 |
| 2.20 | Operação com variáveis qualitativas | 31 |
| 2.21 | Valores limites entre duas regiões adjacentes | 32 |
| 2.22 | Treze relacionamentos possíveis entre dois intervalos de tempo | 33 |
| 2.23 | Representação qualitativa da pressão sistólica | 34 |
| 2.24 | Funções de pertinência para a pressão sistólica | 34 |
| 2.25 | Árvores geradas ao operar duas variáveis qualitativas | 36 |

| | | |
|------|--|-----|
| 3.1 | Cálculo do fator de certeza combinado de duas regras com a mesma hipótese baseado na evidência incerta | 46 |
| 3.2 | Uma função de pertinência para o conjunto nebuloso “Alto” | 55 |
| 3.3 | A função de pertinência S | 56 |
| 3.4 | A função de pertinência Z | 56 |
| 3.5 | A função de pertinência Π | 57 |
| 3.6 | A função de pertinência Triangular | 57 |
| 3.7 | A função de pertinência Trapezoidal | 58 |
| 3.8 | Funções de pertinência para os valores típicos da variável linguística “estatura” | 59 |
| 3.9 | Estrutura básica de um sistema nebuloso | 61 |
| 3.10 | Funções de pertinência para a pressão sistólica | 61 |
| 3.11 | Funções de pertinência para os conjuntos nebulosos de saída | 63 |
| 4.1 | Diferentes tipos de raciocínio | 68 |
| 4.2 | Etapas do processo de decisão | 70 |
| 4.3 | Modelo da lente de Brunswick | 71 |
| 6.1 | Como um sistema especialista baseado em regras resolve problemas | 91 |
| 6.2 | Como um sistema especialista baseado em casos resolve problemas | 91 |
| 6.3 | O ciclo do Raciocínio Baseado em Casos | 94 |
| 6.4 | Estrutura do Sistema Especialista para Diagnóstico Médico por Analogia Nebulosa (SEDMAN) | 95 |
| 6.5 | Ativação da base de casos pelo caso novo | 97 |
| 6.6 | Função de pertinência para o sintoma “Febre” | 97 |
| 6.7 | Tela de apresentação do sistema SEDMAN | 99 |
| 6.8 | Tela principal do sistema SEDMAN | 101 |
| 6.9 | Tela para carregar arquivos no sistema SEDMAN | 101 |
| 6.10 | Tela para guardar arquivos no sistema SEDMAN | 102 |
| 6.11 | Tela para mostrar a lista de pacientes no sistema SEDMAN | 102 |
| 6.12 | Tela para entrada dos dados do paciente no sistema SEDMAN | 103 |
| 6.13 | Tela de diagnóstico fornecido pelo sistema SEDMAN | 103 |

Lista de Tabelas

| | | |
|------|--|----|
| 2.1 | Regras para o exemplo do caminhão | 24 |
| 3.1 | Algumas características de medidas de crença, descrença e fatores de certeza | 42 |
| 3.2 | Regras do MYCIN para combinação das evidências dos antecedentes de expressões elementais | 44 |
| 3.3 | Comparações entre a teoria Dempster-Shafer e a teoria da probabilidade | 49 |
| 3.4 | Confirmação de evidências | 50 |
| 3.5 | Combinação da evidência adicional m_3 | 50 |
| 3.6 | Variáveis linguísticas e seus valores típicos | 59 |
| 3.7 | Algumas regras heurísticas envolvendo variáveis linguísticas significativas | 59 |
| 3.8 | Tabela de verdade para duas declarações e quatro operadores | 60 |
| 3.9 | Tabela de regras de controle nebuloso para a pressão sistólica | 62 |
| 3.10 | Sistemas especialistas e ferramentas utilizando a teoria de conjuntos nebulosos | 64 |
| 6.1 | Sistemas especialistas desenvolvidos com RBC | 90 |

Abreviaturas

A: Artrite

AR: Artrite Reumatóide

G: Gota

GPEB: Grupo de Pesquisas em Engenharia Biomédica

LES: Lupus eritematoso sistêmico

L: Lupus

IA: Inteligência artificial

IAM: Inteligência artificial em medicina

P: Poliarterite

PS: Pressão sistólica

RBC: Raciocínio baseado em casos

RNAs: Redes neuronais artificiais

SE: Sistema especialista

SEDMAN: Sistema especialista para diagnóstico médico por analogia nebulosa

Resumo

Uma das principais dificuldades que apresentam os sistemas especialistas para apoio à tomada de decisão na área médica é que a imprecisão contida nos dados a serem utilizados esquecem-se nos sistemas baseados em computador, fazendo-o eles ficarem diferentes à realidade. Neste trabalho, depois de uma revisão dos principais métodos para tratar com incerteza e imprecisão, um método para tratar a imprecisão nos dados clínicos utilizando a lógica nebulosa é proposto. O Raciocínio Baseado em Casos é um paradigma simbólico da inteligência artificial para modelar o raciocínio do especialista. Este paradigma foi adotado para evitar a perda intrínseca da informação dos sistemas nebulosos baseados em regras. A teoria pesquisada é ilustrada pela implementação de um protótipo experimental no domínio da reumatologia.

Palavras-Chave: Inteligência Artificial, Raciocínio Baseado em Casos, Sistemas Especialistas, Lógica Nebulosa, Imprecisão e Incerteza.

Fuzzy Expert System in Medical Diagnosis

Abstract

One of the main difficulties present in expert systems for medical decision support is that the imprecision contained in data to be used is neglected in computer based systems, making them different from reality. In this work, after a preview of the main methods to deal with uncertainty and imprecision, a method to treat imprecision in clinical data using fuzzy logic is proposed. Case-Based Reasoning is an artificial intelligence symbolic paradigm for modelling expert reasoning. It was adopted in order to avoid the intrinsic information loss in fuzzy rule based systems. The researched theory is illustrated by the implementation of a experimental prototype in the domain of rheumatology.

Keywords: Artificial Intelligence, Case-Based Reasoning, Expert Systems, Fuzzy Logic, Imprecision and Uncertainty.

Capítulo 1

Introdução

As informações que os médicos dispõem sobre seus pacientes em geral são caracterizadas pela incerteza de seu conteúdo. Mas ainda assim os médicos são capazes de chegar a conclusões a respeito desses dados [2].

O conhecimento do mundo real caracteriza-se por ser:

- Incompleto.
- Impreciso.
- Inconsistente.

Mas o homem acostumou-se a buscar precisão e exatidão nos dados, esquecendo que nem sempre essas características podem ser encontradas nas informações usadas para tomar decisões. A tomada de decisão clínica é um claro exemplo disto, o médico durante suas horas de trabalho enfrenta casos caracterizados por dados imprecisos, incompletos e, em alguns casos, de natureza contraditória nos sintomas relatados pelo paciente. Entre estes dados tem-se:

1. História do paciente: Durante a anamnese a informação dada pelo paciente é altamente subjetiva. Pode-se encontrar exageros ou sintomas subestimados. Ignorância de doenças prévias dele ou de sua família, erros na descrição de cirurgias prévias. No entanto, a informação que finalmente leva ao diagnóstico correto é muitas vezes achada na história clínica.
2. Exame físico: Os médicos submetem o paciente a um exame físico para obter dados mais objetivos. Mas, eles médicos poderiam cometer erros ao não considerar indicações importantes ou enganar-se ao realizar o exame completo.

Além disso, eles poderiam interpretar inadequadamente outras indicações porque o limite entre o normal e o patológico não é claramente definido.

3. Resultados de testes laboratoriais: Os resultados de laboratório são considerados como dados objetivos. Mas deve-se lembrar que, erros nas medições, etiquetas erradas nas amostras, amostras no laboratório errado, etc., ou comportamento inadequado do paciente no instante prévio ao teste, poderiam levar a imprecisões e algumas vezes a dados totalmente incorretos.

Por outro lado, os limites entre resultados normais e patológicos são geralmente imprecisos: existem valores de fronteira dos quais não se pode dizer se são normais ou não.

4. Resultados de exames complementares: Tais como os obtidos em exames de raios X, ultra-som, tomografia, ressonância magnética e outros exames clínicos, os exames histológicos dependem de interpretações corretas pelo médico ou outro encarregado. Tais descobertas são cruciais, porque elas frequentemente indicam terapia invasiva. Em muitos casos considerações de imprecisão são parte dos procedimentos de avaliação; por exemplo, contagem de células, determinação do tipo de células, análise descritiva, etc.

Em resumo, pode-se afirmar que os dados com os quais o médico tem que lidar são na sua maioria informações imprecisas, inexatas e incertas.

1.1 Justificativas

Inteligência Artificial(IA) para a tomada de decisão é geralmente associada com os sistemas especialistas de consulta que foram introduzidos nos anos 70. Estes diferem consideravelmente dos métodos de reconhecimento de padrões e daqueles com intensos dados estatísticos que foram aplicados a problemas de raciocínio clínico desde os anos 60, que resurgiram nos anos 80 com novos tipos de sistemas computacionais mais poderosos: foram desenvolvidas as Redes Neurais Artificiais (RNAs) e modelos mais sofisticados de redes de crença e Bayesianas, para capturar a nuance do raciocínio clínico [48]. Nos anos 90 há um incremento em reconhecer que provavelmente são necessárias uma grande variedade de abordagens para fazer sistemas de apoio à decisão clínica [17], baseado em computador, mais úteis e efetivos; mas apesar de ter transcorrido três décadas de pesquisa e inovação tecnológica,

eles ainda não chegaram a ser ferramentas indispensáveis dentro do cenário clínico. Do lado positivo, no entanto, desenvolvem-se programas avançados que incrementam e incorporam neles rotinas, idéias e métodos de IA, para facilitar as tarefas de construção, avaliação e prova das bases de conhecimento clínico.

A evolução de métodos de IA em medicina (IAM) pode-se dividir em quatro períodos:

1. O primeiro, pode ser grosseiramente datado de 1968 à 1976, quando foram apresentados os precursores da tomada de decisão no diagnóstico, em termos das características da solução do problema. Nesta etapa deram-se as primeiras estruturas gerais sobre conhecimento aprofundado para representar o raciocínio clínico acompanhando o processo da doença, por exemplo:

- CASNET [88] : introdução de redes causais para a descrever o processo da doença,
- MYCIN [79]: raciocínio modular baseado em regras ,
- DIALOG [68]/INTERNIST-1 [55]: redes bayesianas hierárquicas,
- PIP [63]: estruturas ou padrões para definição das doenças

Estes sistemas do mesma maneira que os que não usavam técnicas de IA, que os precederam, foram projetados como ferramentas consultivas para assistir ao médico não especialista, enfermeiros e outros praticantes em cuidados da saúde, pela captura de algumas regras do raciocínio do clínico especialista em uma área específica. O sucesso destes protótipos ajudou a mudar as pesquisas em IA para o paradigma de sistemas baseados em conhecimento, que requerem o engenheiro de conhecimento para sua construção. Este desenvolvimento enfoca sua atenção sobre a natureza especializada do conhecimento necessário em tais sistemas.

2. Uma segunda fase da evolução de SE em IA pode ser datada de 1977 à 1982, quando *frameworks* gerais foram construídos para bases de conhecimento especializado, tais como EMYCIN [87], EXPERT [89] e AGE [60]. Os problemas de aquisição do conhecimento e aprendizagem foram também abordadas, inicialmente em um caminho sistemático durante este período e a natureza categórica de muitos raciocínios dentro de SE foi reconhecida [84].

3. O terceiro período de 1983 à 1987, pode ser caracterizado como um período de transição, durante o qual as pesquisas em IAM examinaram a complexidade do raciocínio clínico e desenvolveram modos únicos de representá-los no computador: crítica como uma modalidade de raciocínio, modelos explicativos qualitativos de raciocínio clínico e a elaboração de métodos baseados em regras para atualização e refinamento.
4. O quarto período, desde 1988 até hoje, pode ser caracterizado pelo contínuo desenvolvimento de representações baseadas no conhecimento com estruturas grandes e tarefas genéricas dependentes. Havendo experimentos em raciocínio qualitativo e modelagem e controle de processos de tempo crítico como em Unidades de Tratamento Intensivo. O mais notável foi um renascimento do interesse em abordagens estatísticas para a tomada de decisão, vinculados agora a modelos mais abstratos de processos subalternos em diagrama de influência. Trabalhos sobre métodos Bayesianos [14] e continuações de desenvolvimento na aplicação de redes neurais [11], lógica nebulosa [41], e uma variedade de métodos de aprendizagem para a tomada de decisão caracterizam o incremento de complexidade e diversidade de um campo ativo de pesquisa em evolução.

No Grupo de Pesquisas em Engenharia Biomédica (GPEB) da Universidade Federal de Santa Catarina, o interesse pela aplicação de IA nasceu com o artigo de “Inteligência Artificial” de W.C. de Lima e J.M. Barreto [50] no ano de 1987. O GPEB vem desenvolvendo pesquisas na linha da IA tanto simbólica como conexionista, dentre elas tem-se: SE para diagnóstico de icterícia [58], SE para o ensino na área de treinamento de infecção hospitalar [69], SE híbrido em anestesiologia [31], RNAs em SE dinâmicos [7], SE para detecção e classificação de crises epilépticas [49], SE para aquisição de conhecimento aplicado ao diagnóstico de epilepsia [15], SE estatístico para apoio a pesquisas médicas [57], SE para auxílio ao ensino em traumatologia [59], SE de ensino via sociedade de multiagentes aplicado ao diagnóstico de epilepsia [70], SE por analogia e aprendizado evolucionário aplicado ao diagnóstico clínico [51], pesquisas em aprendizado baseado em casos em modelos de redes conexionistas [81], aplicações de aprendizado de máquina em SE na área médica [18].

Na década passada houve também uma redefinição dos objetivos, por muitos pesquisadores, para objetivos mais factíveis para sistemas de decisão médica, propuseram-se conjuntos alternativos de representações, abordagens de inferência e outros requisitos envolvendo os seguintes pontos:

- Representar a incerteza e imprecisão de modo mais flexível e mais efetivo. Com efeito, até bem recentemente os conceitos de imprecisão e incerteza eram tratados por métodos semelhantes, como se evidencia com as conversas de Zadeh e Bellman, no T. Watson Research Center ainda no início dos anos 60, e que deram como resultado a publicação do artigo *Fuzzy Sets* (Conjuntos Nebulosos) [91], seguido por outros com Bellman e que hoje se seguem com inúmeros trabalhos nas mais diferentes áreas do conhecimento.
- Representar com mais detalhes o conhecimento médico de modo a justificar um diagnóstico, prognóstico ou decisão terapêutica por ele realizado, isto é , possa oferecer explicações claras de como chegou ao resultado.
- Desenvolver um componente descritivo do conhecimento médico ao qual poderia-se aplicar alguma estratégia de resolução de problemas ou inferência.
- Capacidade de auto-aprendizagem (para manter-se atualizado); convém notar que os avanços em inteligência artificial, tem colaborado de modo significativo para melhor compreensão de mecanismos do aprendizado [76].

1.1.1 Tratamento da incerteza e imprecisão em SE de apoio à decisão em Medicina

Um dos requisitos que deve ser considerado no desenvolvimento de SE de apoio à decisão em medicina é o tratamento da incerteza e imprecisão. Muitos métodos formais de inferência foram procurados e aplicados na tomada de decisão clínica abordando este problema. Estes métodos incluem a aplicações de:

- Redes Bayesianas [14],
- Fatores de certeza [16],
- Lógica nebulosa [2] [30], e
- Teoria da evidência de Dempster-Shafer [78].

Alguns destes métodos foram aplicados em sistemas baseados em regras e em sistemas conexionistas [48].

Os dois maiores problemas interrelacionadas que afetam o manuseio da incerteza na tomada de decisão foram: a combinação das evidências de múltiplas fontes

relacionadas em um problema de inferência com várias hipóteses não mutuamente exclusivas e como representar o fluxo da incerteza entre evidências e hipóteses representadas em uma forma causal e hierárquica. Estes problemas existem desde o início das pesquisas de IA, e seu tratamento formal foi feito através do uso de métodos heurísticos empíricos na primeira geração de sistemas. As pesquisas atuais estão na busca de soluções para estes problemas. A teoria Dempster-Shafer fornece um bom formalismo para incorporar informação de crença parcial em uma rede complexa de hipóteses. No entanto, na prática, provou ser computacionalmente muito exigente ou produzir limites de confiança muito amplos ou sem informação para as crenças nas hipóteses, ao final de longas cadeias de raciocínio. Em uma tentativa de fornecer uma conexão entre a semântica das hipóteses relacionada a diferentes níveis de causalidade e abstração, foram desenvolvidos métodos para propagar a incerteza dentro de uma estrutura Bayesiana de tomada de decisão. A aplicação mais sistemática destas técnicas em sistemas médicos e a pesquisa de suas implicações em problemas de raciocínio médico específico, no entanto, estão ainda em andamento. A lógica nebulosa pode ser utilizada para o tratamento da imprecisão. Mas, se o sistema tem longas cadeias de regras, pode acarretar perda de informação. Uma maneira de evitar esta dificuldade é utilizar o paradigma do RBC, o qual não utiliza regras. Neste paradigma, o novo problema é resolvido pela descoberta de um caso passado similar, e reutilizando-o, na solução do novo problema.

1.2 Objetivos Gerais

O objetivo da presente pesquisa é evidenciar as vantagens do uso dos conceitos da lógica nebulosa desenvolvida por Lofti Zadeh em 1965 [91], no tratamento da imprecisão em sistemas especialistas de apoio à tomada de decisão em Medicina. A modo de exemplo será desenvolvido um protótipo do sistema especialista **Sistema Especialista para Diagnóstico Médico por Analogia Nebulosa SEDMAN** e testado no diagnóstico de Reumatismo.

1.3 Objetivos Específicos

- Estudar as formas de raciocínio sob incerteza.

- Estudar métodos de tratamento da imprecisão e/ou incerteza na tomada de decisão, analisando as vantagens e desvantagens dos mesmos em sistemas especialistas (SE).
- Estudar os métodos de raciocínio e a tomada de decisão do clínico.
- Estudar o paradigma do Raciocínio Baseado em Casos (RBC) para a implementação do SE.

Dos objetivos específicos acima expostos pretende-se mostrar as vantagens do tratamento da imprecisão em sistemas especialistas com a lógica nebulosa.

Para expor todos os objetivos específicos a presente dissertação divide-se nos seguintes capítulos:

1. Introdução.
2. Raciocínio Impreciso e Incerto.
3. Tratamento da Imprecisão e Incerteza.
4. Raciocínio Clínico e a Tomada de Decisão.
5. Área de Aplicação.
6. Sistema Especialista Nebuloso para Diagnóstico Médico.
7. Discussão e Conclusões.

Capítulo 2

Raciocínio Impreciso e Incerto

Neste capítulo várias formas de raciocínio impreciso e incerto serão apresentados. Este tópico é muito importante em SE desde que muitas aplicações em SE envolvem informação deste tipo e muito em particular em SE de apoio à decisão médica.

A incerteza e a imprecisão das informações podem ser consideradas como a falta de informação adequada para a tomada de decisão. Tratar um problema impreciso ou incerto como preciso e determinístico pode impedir o encontro da melhor decisão podendo igualmente causar uma má decisão. Na medicina, a incerteza pode impedir o melhor tratamento para um paciente ou contribuir a uma terapia incorreta.

Um número de teorias foram criadas para o tratamento da incerteza e imprecisão. Estas incluem probabilidade clássica, probabilidade Bayesiana, teoria de Dempster-Shafer e a teoria de conjuntos nebulosos de Zadeh.

Um requisito esperado nos SE de apoio à decisão médica é que estes consigam representar a incerteza e imprecisão que se encontram inerentes, no processo de diagnóstico (por exemplo: anamnese, testes laboratoriais, etc.), e assim possam se aproximar ou representar mais fidedignamente o raciocínio médico, de modo que possa chegar ao resultado, que é o diagnóstico, com um grau de certeza tanto quanto o especialista é capaz de fazê-lo.

2.1 Formas de Raciocínio

O raciocínio é a faculdade humana de chegar a conclusões a partir de conhecimentos ou informações sobre um problema.

Na continuação apresentam-se algumas formas de raciocínio. O estudo desta questão permite visualizar como são tratadas a incerteza e imprecisão contidas nas

informações sobre as quais baseia-se o processo de raciocínio:

- Raciocínio Plausível
- Raciocínio Probabilístico
- Raciocínio Nebuloso
- Raciocínio Qualitativo

2.1.1 Raciocínio Plausível

Raciocínio Plausível é a maneira de chegar a uma conclusão a partir do conhecimento de evidências sobre o fato que se está analisando.

Estritamente falando, todos os nossos conhecimentos externos à matemática e à lógica demonstrativa, consistem de conjecturas. Existem, conjecturas e conjecturas. Há conjecturas respeitáveis e formais como as expressas em certas leis da ciência física e há outras conjecturas que não são formais, nem respeitáveis, porém elas poderiam ser aceitas ou não. E assim por diante tem-se toda sorte de conjecturas, pressentimentos e suposições [66].

Os conhecimentos matemáticos são assegurados pelo raciocínio demonstrativo, mas nossas conjecturas são mantidas pelo raciocínio plausível. A comprovação matemática é raciocínio demonstrativo, mas as evidências não o são. Por exemplo, a evidência indutiva do físico, a evidência circunstancial do advogado, a evidência documentaria do historiador, a evidência de sinais e sintomas do médico pertencem ao raciocínio plausível

Há diferenças entre os dois tipos de raciocínio. O raciocínio demonstrativo é seguro, longe das controvérsias e final. O raciocínio plausível é arriscado, com controvérsias e transitório. O raciocínio demonstrativo está nas ciências da mesma forma como a matemática, em si mesmo, isto é, não produz em essência novos conhecimentos do mundo real. Alguma coisa nova que se aprende sobre o mundo envolve raciocínio plausível, sendo assim é o tipo de raciocínio pelo qual se tem interesse no dia a dia. O raciocínio demonstrativo tem padrões rígidos, codificados e tratados pela lógica demonstrativa, a qual é a teoria do raciocínio demonstrativo. Os padrões do raciocínio plausível são claros, e não há teoria de tal raciocínio que possa ser comparado à lógica demonstrativa, em clareza e que possa ter consenso.

Os raciocínios demonstrativo e plausível não contradizem um ao outro; pelo contrário se completam. No raciocínio demonstrativo o assunto principal é distinguir uma demonstração a partir de uma suposição, uma demonstração válida a partir de uma tentativa inválida. No raciocínio plausível o objetivo principal é distinguir uma suposição de outra, uma suposição mais razoável de uma suposição menos razoável.

O uso eficiente do raciocínio plausível é uma habilidade prática e leva à aprendizagem, como em qualquer outra habilidade prática, por imitação e método (exercício).

No raciocínio plausível trabalha-se com suposições e transitoriedade, envolvendo processos tais como: experiência, indução, generalização, especialização e analogia. Que a seguir serão apresentados :

Experiência

A experiência é o conhecimento de coisas pela observação, ela modifica o comportamento. Aprende-se ou deveria-se aprender com as experiências. O homem deveria fazer o maior uso possível da experiência.

Indução

A indução geralmente inicia com a observação. E leva intrinsecamente ao raciocínio que permite chegar a uma conclusão genérica do fato observado (ver figura 2.1).

Por exemplo, um biólogo poderia observar a evolução da vida numa bactéria. Para que ele tenha chances de obter resultados interessantes de sua observação, deveria estar familiarizado com a evolução das bactérias. Similarmente, se um médico deseja obter algum resultado relevante ao observar a patologia do reumatismo, deveria estar familiarizado com ela. Porém, para distinguir a artrite reumatóide do lupus eritematoso, deveria conhecer os sintomas e as características particulares destas patologias. Isto é, o observador deve estar embasado em alguma teoria a respeito daquilo que observa.

Generalização

É passar desde a consideração de um conjunto de objetos a um conjunto maior que contenha o anterior (ver figura 2.2).

Por exemplo, o médico generaliza quando passa de sintomas característicos de diferentes patologias das articulações ao reumatismo. Frequentemente generaliza-



Figura 2.1: Processo indutivo

mos quando passamos de sintomas característicos à uma patologia que contém os sintomas.

Especialização

É passar desde a consideração de um conjunto de objetos a um conjunto menor que está contido no anterior (ver figura 2.3).

Por exemplo, o médico faz um processo de especialização quando passa desde a consideração de sintomas das doenças das articulações aos sintomas específicos que caracterizam cada tipo de patologia: lupus eritematoso, artrite reumatóide, gota, poliarterite, etc. Muito frequentemente nos especializamos ao passar de uma classificação geral de doenças a uma classe específica da patologia.

Analogia

Informalmente pode-se dizer que analogia é um tipo de similaridade. Esta similaridade se dá em um nível claramente definido e conceitual. Na analogia toma-se somente as características relevantes que identificam o objeto em consideração, sendo estas características definidas de acordo com as intenções do observador. Casos similares possuem entre si alguns aspectos comuns. Quando se faz a redução dos aspectos comuns para conceitos claramente definidos, considera-se estes casos




Figura 2.2: Processo de generalização

similares como análogos.

Dois sistemas são análogos, se forem similares em relações claramente definidas de suas respectivas partes. Se um fato novo observado é similar a outro já conhecido e sobre o qual já se tem uma opinião, então pode-se ter uma opinião sobre o fato novo baseado na experiência anterior, isto é, chega-se a um resultado por analogia (ver figura 2.4).

Por exemplo, um reumatologista iniciante encontra-se com o seguinte quadro clínico: febre, dor sem deformidades em uma ou mais articulações periféricas, ele lança um diagnóstico inicial: “trata-se de um caso de lupus eritematoso sistêmico (LES)”, ele fundamenta essa conjectura por indução. Isto é, foi sugerida pela observação e indicado para este caso particular.

Estes sintomas observados no paciente não são suficientes para ele chegar ao diagnóstico; pois não tem muita experiência em LES para acreditar na sua conjectura inicial, mas vai se apoiar nas informações que possui de casos já vistos. Agora, tentar-se-á explicitar os passos feitos no raciocínio clínico: O médico começa observando os sintomas e sinais da patologia, para ter experiência a respeito. A seguir, ele generaliza os sintomas e sinais chegando à conclusão de que se trata, neste exemplo, de uma patologia das articulações. Depois, ele vai se especializar e identificará cada uma das doenças contidas no grupo de patologias das articulações. Finalmente, ao voltar para comparar com outros pacientes que tiveram sintomas similares, com

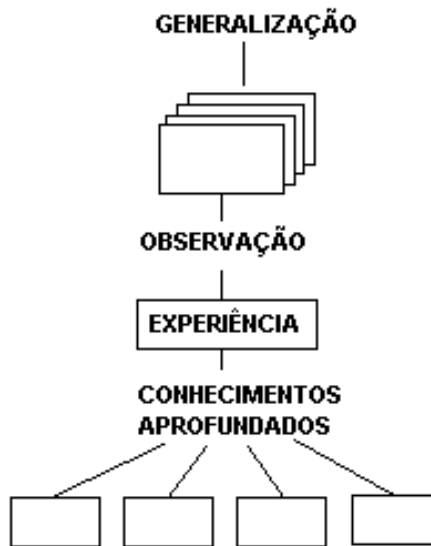


Figura 2.3: Processo de especialização

alguma variação na intensidade ou duração, ele estará fazendo analogia.

Com o objetivo de resumir raciocínio plausível, apresentam-se os **Padrões da inferência plausível de George Polya** [67]. Dentre aqueles são considerados de maior ênfase os seguintes:

- **Padrões Indutivos**

“A verificação de uma consequência torna a conjectura mais credível”. Uma conjectura pode ser escrita como a premissa numa regra contida no processo do raciocínio. Por exemplo, a conjectura *“choveu ontem a noite”* chega a ser mais credível quando verifica-se a consequência *“o chão está molhado”*. Sendo ambos considerados na seguinte regra: *“Se choveu ontem a noite então o chão deve estar molhado”*.

- **Verificação sucessiva de várias consequências**

“A verificação de uma nova consequência vale mais ou menos se a nova consequência difere mais ou menos da anterior, consequência verificada”. Por exemplo, ao se tentar verificar a conjectura *“Todas as bananas tem casca amarela”*, observa-se n bananas colombianas, todas elas de casca amarela. Nossa subsequente confiança nesta conjectura incrementa-se substancialmente se a



Figura 2.4: Processo de analogia

$(n + 1)$ -ésima banana é uma banana brasileira mais amarela do que outra banana da Colômbia. Tal não ocorreria se esta $(n + 1)$ -ésima banana fosse uma banana figo com sua casca escura.

- **Verificação de conseqüências verossímeis**

“A verificação de uma conseqüência vale mais ou menos, de acordo se a conseqüência é mais ou menos verossímil em si mesma”. Por exemplo, tem-se duas expressões: “Se ontem a noite choveu, então o teto está pingando” e “Se ontem a noite choveu, então a grama está molhada”, pode-se perceber que o conseqüente da primeira expressão tem mais suporte do que o conseqüente na segunda expressão.

- **Inferência desde analogia**

“A conjectura chega a ser mais credível quando uma conjectura análoga resulta ser verdadeira”. Por exemplo, a conjectura “O paciente apresenta queda de cabelo, febre e eritema facial, ele pode ter LES” chega a ser mais credível quando provamos a conjectura relacionada “Um dos quadros clínicos característicos do LES é: alopecia, febre e eritema facial”.

Polya questionou-se sobre se estes padrões poderiam ser considerados como regras do raciocínio plausível. Vejamos, algumas pessoas desconfiam das “regras” e confiam em sua “intuição” ou “experiência” ou “intuição-e-experiência” [67]. Por exemplo:

1. Um cirurgão pode não ter regras na tomada de decisão, a decisão dele pode custar uma vida e algumas vezes, quando um paciente começa a sangrar ou a se sufocar, a decisão adequada deve ser tomada em alguns segundos. Porém ele

não usa regras. O tempo é muito curto para aplicar regras apropriadamente, e qualquer conjunto de padrões poderia enganá-lo.

2. Apresenta-se a mesma evidência a dois jurados e seguindo o mesmo procedimento eles podem julgar diferentemente: um pensa que a evidência é suficiente à prova do defendido e o outro pensa que não. Essas diferenças podem ter diferentes bases: um deles pode ser um ótimo observador de comportamento, ele observa as expressões do rosto, ele é impressionado pelos movimentos de olhos e mãos do acusado. O outro jurado pode não ser um bom observador, ele compreende melhor o meio social e as circunstâncias das pessoas envolvidas no caso. E assim eles chegam a resultados diferentes. Isto é, duas pessoas com a mesma evidência podem discordar honestamente.
3. Duas pessoas encontram-se interessadas na conjectura A (Uma delas é engenheiro, e A é uma conjectura relacionada à engenharia). Ambas sabem que A implica B . Depois que elas acham que B é consequência de A , e B é verdadeiro. Elas concordam que A implica B , mas discordam sob o valor ou peso da evidência. Elas são honestas, mas a base de conhecimento de ambas é diferente, uma delas esta mais relacionada ao fato e a outra não. Observa-se que, apresentada a mesma evidência a duas pessoas e aplicando os mesmos padrões de inferência plausível, eles podem discordar honestamente.

Polya tentou olhar o raciocínio plausível no trabalho, no comportamento das pessoas em frente a problemas concretos. E com os pontos acima expostos, tentou aclarar a idéia na qual seus padrões estão “sujeitos”, e quão longe eles podem ser lembrados como “regras”.

Pode-se dizer que o raciocínio clínico para a tomada de decisão, é um raciocínio plausível, posto que se baseia em evidências que levam a conjecturas (o diagnóstico) que às vezes podem ser arriscadas, controversiais e transitórias, mas ainda assim não criam dúvidas ao médico e não impedem a tomada de decisão. O raciocínio plausível encontra-se embutido no raciocínio clínico, o qual atravessa etapas desde a indução (médico iniciante) até a analogia (médico especialista).

2.1.2 Raciocínio Probabilístico

É o raciocínio que, apoiando-se em informações probabilísticas sobre fatos de um domínio, chega a uma conclusão a respeito de um novo caso.

Neste contexto “*Probabilidade não é sobre números; mas é sobre a estrutura do raciocínio*”. Quando um médico afirma. “*A chance de que um paciente com a doença D , desenvolva mais adiante o sintoma S é p* ”, a verdade da afirmação não é a magnitude precisa de p tanto quanto a razão específica para a crença do médico, o contexto ou a suposição sobre a qual a crença deveria estar firmemente mantida, e as fontes de informação que acarretam mudanças nesta crença [64].

Supõe-se que, por razões de generalidade e economia de armazenamento, esquecem-se algumas experiências ou elas são retidas na forma de média, pesos, ou relações qualitativas abstratas, que ajudam a determinar ações futuras.

Quais seriam as razões para que crenças, sendo disposições mentais sobre eventos não reprodutíveis e frequentemente não observáveis, devam combinar com as leis de probabilidade que governam tentativas repetíveis, tais como os resultados de mecanismos de jogo?. Para responder esta questão, apresentam-se as relações primitivas da linguagem de probabilidade, onde mostra-se que apesar de que as probabilidades são expressas em números, a vantagem da teoria de probabilidade é, fornecer um meio para articular e manipular relações qualitativas. As seguintes relações são olhadas como as primitivas básicas da linguagem:

- Verossimilhança: “*É mais verossímil que um pássaro voe do que caminhe*”;
- Condicional: “*Se o pássaro está doente, ele não pode voar*”;
- Relevância: “*Para o pássaro voar depende dele não estar doente*”;
- Causal: “*A existência da doença originou a inabilitação ao pássaro de voar*”.

Verossimilhança

As relações qualitativas da forma “*A é mais verossímil que B*” foram tradicionalmente percebidas como o primeiro propósito do uso de probabilidade. A importância prática de determinar se um evento é mais verossímil que outro é devido ao fato de que o cálculo de probabilidade foi pioneiro e desenvolvido por jogadores como Cardano [1501-1576] e De Moivre [1667-1754]. No entanto, a importância das relações de verossimilhança vai mais longe de situações de jogo ou ainda na tomada de decisões. As decisões dependem de verossimilhanças relativas aos eventos para considerar os resultados da aplicação de uma determinada regra ou para adquirir mais informação. Verossimilhanças são importantes em todas as tarefas de

raciocínio devido ao traslado dessas imediatamente para tempo processado, isto é, o tempo que leva para verificar a verdade da proposição. Um sistema de raciocínio que não faz considerações de verossimilhança poderia desperdiçar recursos valiosos em procurar o não verossímil, enquanto despreza o verossímil.

Condiciona

A teoria da probabilidade adota a frase epistêmica “... posto que C é conhecido” como uma primitiva da linguagem. Sintaticamente, isto é denotado como:

$$P(A | C) = p$$

onde A é uma dada proposição. Esta frase combina as noções de conhecimento e crença pela atribuição à A de um grau de crença p , dado o conhecimento de C . C é chamado também o contexto da crença em A , e a notação $P(A | C)$ é chamada probabilidade condicional de Bayes. Thomas Bayes [1702-1761] fez sua principal contribuição à ciência de probabilidade pela associação da frase “... dado que se conhece C ” com a famosa fórmula:

$$P(A | C) = \frac{P(A, C)}{P(C)}$$

a qual chegou a ser uma definição de probabilidade condicional. É pela probabilidade condicional de Bayes que a teoria da probabilidade facilita o raciocínio não monotônico, isto é, o raciocínio probabilístico que envolve reavaliação de conclusões prévias. Por exemplo, é bastante aceitável afirmar simultaneamente: A crença na proposição

“ $P(\text{voar}(a) | \text{pássaro}(a))$ é grande”, logo

$P(\text{voar}(a) | \text{pássaro}(a)) \approx 1$ ou poderia estimar-se 0.99

e a crença na proposição

“ $P(\text{voar}(a) | \text{pássaro}(a), \text{doente}(a))$ é baixa”, logo

$P(\text{voar}(a) | \text{pássaro}(a), \text{doente}(a)) \approx 0$ ou poderia estimar-se 0.02

Em outras palavras, sabe-se que o objeto a é um pássaro, pode-se chegar à conclusão que a provavelmente voa. No entanto, sob o conhecimento que a está doente, há uma reavaliação sobre a primeira conclusão e afirma-se que é menos provável que a possa voar.

Para facilitar tais reavaliações são necessárias duas coisas: que a crença original seja estabelecida com uma certeza menos absoluta, e que o contexto sobre a condição

de crença seja consultada constantemente, para ver se na reavaliação a crença é a mesma. A dinâmica da revisão da crença sob mudanças no contexto não é totalmente arbitrária, mas deve obedecer algumas leis básicas de plausibilidade as quais, estão embutidas nas regras sintáticas do cálculo de probabilidades. Um exemplo de tais leis plausíveis é a seguinte regra :

Regra do meio hipotético: “Se duas suposições diametralmente opostas tem dois diferentes graus de crença sobre uma proposição Q , logo o grau incondicional do mérito de crença para Q seria algum valor entre os dois.”

Por exemplo, a crença que B = “Piolin voa” dado que C = “Piolin é um pássaro” pode estar entre a crença de que Piolin voa dado A = “Pássaro saudável” e a crença que Piolin voa dado $\neg A$ = “Pássaro doente”. Esta regra, restrição de senso comum, é construída dentro da sintaxe do cálculo de probabilidade através da seguinte igualdade:

$$P(B | C) = \alpha P(B | C, A) + (1 - \alpha) P(B | C, \neg A)$$

onde: $\alpha = P(A | C)$ é algum número entre 0 e 1.

Relevância

Relevância é uma relação indicando uma mudança potencial de crença devido a uma mudança específica no conhecimento. Duas proposições A e B são chamadas relevantes no contexto C , se a inclusão de B em C pode mudar a verossimilhança de A . Relevância pode ser definida em termos de verossimilhança e condicional. Por exemplo, uma pessoa poderia estar indecisa em avaliar a verossimilhança de dois eventos, mas pode ter confiança para opinar se os eventos são ou não relevantes uns aos outros. As pessoas dão tais opiniões rapidamente e consistentemente, aqui supõe-se que as relações relevantes sejam armazenadas explicitamente como ponteiros na base do conhecimento que possui. Relevância é também uma primitiva da linguagem da teoria de probabilidade, porque a linguagem permite especificar relações relevantes direta e qualitativamente antes de fazer qualquer avaliação numérica. Depois, quando a avaliação numérica de verossimilhança é requerida, ela pode ser adicionada de forma consistente, sem atrapalhar a relevância da estrutura original, através de probabilidade condicional.

Causal

Causalidade é uma noção ubíqua na concepção do homem sobre seu meio ambiente, ainda que tradicionalmente tenha sido considerada uma construção psicológica, externa ao âmbito da probabilidade ou até das ciências físicas [64].

Causalidade é uma linguagem com a qual uma pessoa pode falar eficientemente sobre estruturas de relações relevantes, com o objetivo de separar o relevante do supérfluo. Por exemplo, dizer que o chão úmido foi uma causa direta do escorregamento e fratura da perna de uma pessoa é um caminho conciso para identificar que eventos não deveriam ser considerados relevantes ao acidente, assim que a umidade do pavimento seja confirmada. O fato que choveu esse dia e que uma outra pessoa também escorregou e fraturou sua perna não devem ser considerados relevantes ao acidente, desde que se estabeleceu a verdade do “chão úmido” e se identificou como uma causa direta do acidente.

O estabelecimento de uma relação causal segue padrões de dependência: Dois eventos não chegam a ser relevantes entre si somente pelo fato de predizerem uma consequência comum, mas eles chegam a ser relevantes quando a consequência é realmente observada. Resumindo, pode-se afirmar que dois eventos com relação de causalidade são relevantes, mas nem todos os eventos relevantes tem causalidade.




Figura 2.5: Grafos direcionados

O raciocínio probabilístico é útil para modelar sistemas onde há a presença de incerteza, isto é, a ocorrência de um conjunto de evidências E leva a um vetor (V) de probabilidades das hipóteses concorrentes. Cada elemento de V representa a probabilidade condicional $P(H_i | E)$. A aquisição de conhecimento do especialista deve permitir chegar-se a uma base de conhecimentos representada como uma rede Bayesiana, contendo informações verossímeis, relevantes e com relações causais (figura 2.5).

As relações entre A , B e C são representadas utilizando grafos direcionados, onde aos arcos de ligação estão associadas probabilidades condicionais. Tem-se tentado

solucionar os problemas de propagação de incerteza nas redes Bayesianas, através da máxima entropia.

2.1.3 Raciocínio Nebuloso

O raciocínio nebuloso pode-se dizer que se originou nas discussões dos gregos antigos sobre valores de verdade. Sócrates com suas perguntas a seus discípulos formulou o problema de números de verdades sem dar resposta. A corrente platônica afirmava que existiam dois valores de verdade. Mas estas discussões evoluíram até que Aristóteles, aluno de Platão, que iniciou a lógica modal com quatro valores de verdade, a qual permaneceu quase no esquecimento até nosso século. As discussões filosóficas sobre o axioma do terceiro excluído (*excluded middle*), onde um elemento pode ser verdadeiro ou falso, e não pode ter uma terceira possibilidade (não pode ser verdadeiro e falso ao mesmo tempo), geraram paradoxos, por exemplo: “o paradoxo do barbeiro: Em uma pequena cidade onde só existia um barbeiro. O barbeiro recebeu a missão de barbear todos os homens que não se barbeavam a si mesmos. Todos os homens deveriam estar barbeados senão morreriam. Pergunta: Quem barbeia o barbeiro?” [13].

O raciocínio nebuloso foi formalizado após a publicação do artigo de Zadeh [91] nos anos 60, quando criou a Teoria de Conjuntos Nebulosos. Esta idéia foi resultado de conversas entre Zadeh e Bellman durante um ano sabático do Zadeh. Eles discutiram a diferença entre os conceitos de imprecisão e incerteza, ambos tratados na época pela mesma ferramenta.

Em particular, a imprecisão (*fuzziness*) intrínseca da linguagem natural é uma consequência lógica da necessidade de expressar informação em forma resumida [92]. Segundo Dubois e Prade, aproximar é equivalente a raciocínio nebuloso e representa o processo ou processos pelos quais uma possível conclusão imprecisa é deduzida desde uma coleção de premissas imprecisas [28]. Tal raciocínio é, na maior parte, de natureza qualitativa mais do que quantitativa e quase tudo isto cai fora do domínio da aplicabilidade da lógica clássica.

O raciocínio nebuloso é um raciocínio que baseado em dados imprecisos, os quais são representados por graus de pertinência a um conjunto nebuloso, chega a uma conclusão.

No raciocínio nebuloso trabalha-se com imprecisão, envolvendo processos tais



Figura 2.6: Função de pertinência

como: nebulização (*fuzzification*), denebulização (*defuzzification*). E para uma melhor compreensão deles precisa-se da definição de alguns conceitos que serão apresentados na continuação (figura 2.6):

- função de pertinência: define um conjunto nebuloso mapeando entradas abruptas (*crisp*) de seu domínio a graus de pertinência.
- grau de pertinência: grau ao qual um valor abrupto é compatível com uma função de pertinência, o qual pode tomar valores dentro de um intervalo pre-determinado, por exemplo: $[0, 1]$.
- etiqueta: nome descritivo, utiliza-se para identificar uma função de pertinência.
- domínio: valores (geralmente números) sob os quais é definida a função de pertinência.
- universo de discurso: todos os valores possíveis de uma variável do sistema.

Agora, para explanar o caminho do raciocínio nebuloso suponha-se o seguinte sistema (figura 2.7). Este sistema mapeia entradas abruptas em saídas abruptas e é basicamente formado por quatro componentes:

- Regras

Podem ser fornecidas pelo especialista ou ser extraída de dados numéricos. Em ambos casos as regras de inferência são expressas como declarações do tipo “*SE.....ENTÃO*”. Por exemplo: “*SE dor na parte baixa e movimento da espinha lombar é limitado e expansão torácica diminuída e paciente mulher e idade entre 20 e 40 anos ENTÃO espondilite anquilosante*” [2]. Esta regra mostra que precisa-se de uma compreensão de:




Figura 2.7: Sistema de lógica nebulosa

1. variáveis linguísticas versus valores numéricos das variáveis (idade versus 35 anos).
2. variáveis linguísticas quantificadoras (dor pode ter um número finito de termos linguísticos relacionados com ela, eles podem ir desde extremamente forte a quase nada) o qual é feito utilizando funções de pertinência nebulosa.
3. conexões lógicas para variáveis linguísticas, p.e. “e” “ou”, etc.
4. implicações, por exemplo “Se A então B ”.

E além de tudo isto, precisa-se entender como combinar mais de uma regra.

- Nebulizador (*fuzzifier*)

Mapeia números abruptos de entrada em conjuntos nebulosos. Isto é necessário para ativar regras as quais estão em termos de variáveis linguísticas, as quais são conjuntos nebulosos associados a eles. Estes conjuntos nebulosos podem ser representados por funções do tipo (a) **impulso** ou (b) **triangular** ou (c) **trapezoidal** ou (d) **S** ou (e) **Z** ou (f) Π , as quais são mostradas na figura 2.8. A função do tipo impulso pode nem sempre ser a mais apropriada, especialmente quando os dados tem uma faixa de valores que também devem ser considerados. As outras funções fornecem maior representatividade da imprecisão para serem manipuladas dentro dos *frameworks* de sistemas de lógica nebulosa

- Motor de Inferência

Mapeia conjuntos nebulosos em conjuntos nebulosos. Este manipula o caminho no qual as regras são combinadas. Da mesma maneira como os humanos utilizam muitos tipos diferentes de procedimentos inferenciais na compreensão




Figura 2.8: Formas de representação de conjuntos nebulosos

de pensamentos ou para a tomada de decisões, existem diversos processos inferenciais em lógica nebulosa, por exemplo tem-se o seguinte sistema para estacionar corretamente um caminhão de retrocesso na doca [54] (figura 2.9):




Figura 2.9: Posição da cabina do caminhão em relação a doca

Quando $x = 10$ e $\phi = 90^\circ$, o valor de θ é o ótimo para estacionar o caminhão, as funções de pertinência para as duas variáveis (figura 2.10), onde S é pequeno, CE é centrado, B é grande.

as regras para este sistema são mostradas na tabela 2.1.

Suponha-se que em T_i $x = 6$ e $\phi = 140^\circ$, observa-se nas funções de pertinência que se ativam dois conjuntos nebulosos, o qual ativa três regras (ver na tabela 2.1):

$R^{5,1}$: Se $\phi \acute{e} B1$ e $x \acute{e} S2$ logo $\theta \acute{e} B2$

$R^{5,2}$: Se $\phi \acute{e} B1$ e $x \acute{e} S1$ logo $\theta \acute{e} B3$




Figura 2.10: Funções de pertinência para o exemplo do caminhão

| $\phi \setminus x$ | S2 | S1 | CE | B1 | B2 |
|--------------------|-----------|-----------|----|----|----|
| S3 | S2 | S3 | | | |
| S2 | S2 | S3 | S3 | S3 | |
| S1 | B1 | S1 | S2 | S3 | S2 |
| C3 | B2 | B2 | CE | S2 | S2 |
| B1 | B2 | B3 | B2 | B1 | S1 |
| B2 | | B3 | B3 | B3 | B2 |
| B3 | | | | B3 | B2 |

Tabela 2.1: Regras para o exemplo do caminhão

$R^{6,2}$: Se $\phi \in B2$ e $x \in S1$ logo $\theta \in B3$

A ativação das regras $R^{5,1}$, $R^{5,2}$, $R^{6,2}$ são mostradas nas figuras 2.11, 2.12 e 2.13 respectivamente.

Os conjuntos nebulosos obtidos usando o t-conorma são mostrados na figura 2.14. Observa-se que as funções de pertinência de saída da inferência **min** apresentam um truncamento no valor de saída nebulosa, este truncamento chama-se λ -corte (λ -cut), a diferença do limiar α -corte (α -cut) que é estabelecida pelo projetista, o λ -corte (figura 2.15(a)) é determinado pela máquina




Figura 2.11: Ativação da regra $R^{5,1}$ e as suas saídas




Figura 2.12: Ativação da regra $R^{5,2}$ e as suas saídas

de inferência nebulosa durante a execução de seu processo. O propósito mais comum do α -corte (figura 2.15(b)) é acelerar o processo de inferência.

- Denebulizador (*defuzzifier*)

Mapeia conjuntos nebulosos de saída em números abruptos. Em uma aplicação de controle, por exemplo, um número corresponde a uma ação de controle, em uma aplicação de processamento de sinais, poderia corresponder a uma previsão do comportamento do sinal observado, ou em uma aplicação de diagnóstico médico a um prognóstico de doença.

Muitos denebulizadores foram propostos na literatura, embora, não existam bases científicas para nenhum deles [54] em consequência, denebulizar é um arte mais do que uma ciência, dentre elas tem-se:

1. Denebulizador máximo, este denebulizador examina o conjunto nebuloso B e escolhe como sua saída o valor de y para o qual $\mu_B(y)$ é o máximo.




Figura 2.13: Ativação da regra $R^{6,2}$ e as suas saídas




Figura 2.14: Os conjuntos nebulosos obtidos utilizando o t-conorma para as inferências: (a) mínimo e (b) produto

Isto pode direcionar a resultados peculiares ou pode ter valores altos sem levar em consideração todos os valores sobre os quais encontra-se representado o conjunto nebuloso.

2. Denebulizador Meio do máximo, este examina o conjunto nebuloso B e primeiro determina o valor de y para o qual $\mu_B(y)$ é o máximo. Logo computa o meio deste valor com sua saída. Infelizmente, isto pode levar a resultados inesperados, suponha-se que B está representado por dois conjuntos nebulosos com a mesma pico de amplitude, este método obterá um valor na metade do caminho entre os dois conjuntos, onde a função de pertinência B tem o valor zero (figura 2.16).
3. Denebulizador do centróide, Este denebulizador determina o centro de gravidade (centróide), \bar{y} , de B e utiliza este valor como a saída do sistema. calculado por:

$$\bar{y} = \frac{\int_S y \mu_B(y) dy}{\int \mu_B(y) dy}$$




Figura 2.15: (a) λ -corte e (b) α -corte em conjuntos nebulosos




Figura 2.16: Exemplo para o qual o denebulizador Meio do máximo não faz sentido

onde S denota o domínio de $\mu_B(y)$. Frequentemente S é discretizado, de modo que \bar{y} pode ser aproximado pela seguinte expressão, a qual utiliza o somatório no lugar da integração:

$$\bar{y} = \frac{\sum_{i=1}^I y_i \mu_B(y_i)}{\sum_{i=1}^I \mu_B(y_i)}$$

O denebulizador do centróide é único, no entanto, este é usualmente difícil de calcular.

Lógica Nebulosa e Probabilidade

Quando se apresenta pela primeira vez a noção de conjuntos nebulosos, as pessoas têm a impressão que é um disfarce da probabilidade, ou pior ainda, que tenta resolver o mesmo tipo de problema. Uma razão poderia ser, que os valores de pertinência e probabilidade se encontram em um intervalo fechado $[0, 1]$.

Existe uma diferença fundamental entre probabilidade e lógica nebulosa a qual, uma vez melhor compreendida, levará a uma cuidadosa diferenciação entre as carac-

terizações de graus de pertinência versus graus de probabilidade, em especial em conversações formais como, diagnóstico médico, e em geral, nessas aplicações nas quais o alto grau de precisão do significado é importante alcançar.

Como os dois conceitos são muito diferentes, serão apresentados duas diferenças: semânticas e axiomáticas de cada conceito [12].

- **Diferenças Semânticas**

A primeira diferença está no significado da pertinência nebulosa e o valor da probabilidade. No conjunto nebuloso, um valor de pertinência entre 0 e 1 significa que o elemento não pertence perfeitamente ao conjunto considerado.

Por exemplo, um homem com uma temperatura de 38 graus tem febre, mas ter 40 graus é ter mais febre. Na terminologia dos conjuntos nebulosos o primeiro homem tem um grau de pertinência ao conjunto de pertinência FEBRE menor do que o segundo homem. Ambos pertencem ao conjunto nebuloso (FEBRE), só que com diferente grau de pertinência.

Continuando com o exemplo de febre, um homem que tem uma infecção provavelmente tem febre porque a infecção causa febre. Nós podemos estabelecer a probabilidade na ocorrência de febre dado que sabemos que o homem tem infecção.

O exemplo anterior mostra a importância na distinção dos conceitos nebuloso e probabilidade, ambos úteis em aplicações biomédicas. Ambos os conceitos podem ser utilizados conjuntamente.

- **Diferenças Axiomáticas**

As diferenças axiomáticas são mais abstratas, mas convincentes. Informalmente, poderíamos dizer que em ambos os casos, pertinência nebulosa e probabilidade, temos uma função com uma gama de valores no intervalo $[0, 1]$. Mas em conjuntos nebulosos o domínio da função é o conjunto universal, e no caso de probabilidades o domínio é um conjunto de partes do universo.

2.1.4 Raciocínio Qualitativo

É aquele que baseia-se em informações qualitativas para chegar a uma conclusão. Este raciocínio envolve dois pontos principais: os valores que podem ser adotados pelas variáveis no espaço quantitativo, e o tempo qualitativo, ou tempo durante o qual os valores qualitativos são válidos [10].

Na literatura existem muitos termos que expressam o conceito do Raciocínio Qualitativo. Encontram-se termos como “Senso Comum”, “Física Qualitativa”, “Física Intuitiva”, todos estes termos fornecem desde suas próprias abordagens o conceito do Raciocínio Qualitativo [19]. Apresentaremos sucintamente cada um deles :

Senso Comum

Algumas pessoas acreditam que o senso comum advém de nosso armazenamento massivo de conhecimento e de nossa capacidade de acessar rapidamente os conhecimentos relevantes no momento certo. Por exemplo, quando escutamos “frente fria”, pensamos em ventos fortes, chuva e outras características a ela associadas. Acessamos nossa memória pelo conteúdo.

Física Qualitativa

Tem por objetivo saber criar e raciocinar com representações abstratas e sem números, por exemplo (ver figura 2.17):




Figura 2.17: Física qualitativa

Na figura, o modelo quantitativo que representa o fenômeno, poderia ser o seguinte: Se a velocidade inicial da bola é V_0 e o ângulo de desvio do solo for θ , então a posição da bola t segundos depois de ter sido lançada será fornecida por:

$$\begin{aligned} \text{altura} &= V_0 \cdot \text{sen}(\theta) - \frac{1}{2} \cdot g \cdot t^2 \\ \text{distância} &= V_0 \cdot t \cdot \text{cos}(\theta) \end{aligned}$$

Mas, muitas pessoas não conhecem essas equações, apesar de serem perfeitamente capazes de prever o que acontecerá. Isto é, as pessoas não precisam de

medidas numéricas exatas. Elas geralmente, só precisam de descrições qualitativas. As pessoas parecem raciocinar mais abstratamente do que indicam as equações.

A física qualitativa procura compreender os processos físicos através da criação de modelos. Um modelo é uma representação abstrata que elimina os detalhes irrelevantes. Por exemplo, para prever a queda de um objeto, deve-se considerar sua massa e não sua forma ou cor. Os modelos da física tradicional são criados a partir de variáveis com valores reais, coeficientes de mudança, expressões, equações e estados. A física qualitativa oferece ferramentas semelhantes, que são mais abstratas e não-numéricas.

Física Intuitiva

É uma metodologia que tenta dirigir a questão de como o homem modela o comportamento de sistemas físicos na ausência do computador, isto é, modelar o processo de entendimento em si mesmo.

Representação de informações qualitativas

1. Variáveis

Na física tradicional, variáveis com valor real são usadas para representar características dos objetos, como posição, velocidade, ângulo e temperatura. As variáveis qualitativas adotam um conjunto ordenado finito de valores qualitativos. Por exemplo, a quantidade de água em um pote pode ser representada por vazio, meio-termo, cheio e a sua temperatura como congelada, meio-termo, fervente

2. Espaços de quantidade

São pequenos conjuntos de valores discretos para uma variável. Os elementos de um espaço quantitativo são normalmente ordenados com base uns nos outros para que um valor possa ser considerado menor que o outro. Por exemplo a idade (figura 2.18).

3. Coeficientes de mudança.

São considerados quando as variáveis assumem valores diferentes em momentos diferentes. Um coeficiente de mudança com valor real (dx/dt) pode ser modelado qualitativamente { diminuindo, estável, aumentando }. Por exemplo a chuva (figura 2.19).




Figura 2.18: Espaços quantitativos




Figura 2.19: Coeficientes de mudança

4. Expressões.

São formadas a partir da combinação das variáveis. Por exemplo: Duas variáveis qualitativas x e y podem ser facilmente somadas. A tabela da verdade para somar variáveis qualitativas é mostrada na figura 2.20.

| | | | | |
|---------------|----------|----------|---|---|
| | | Y | | |
| | | - | 0 | + |
| SOMA = | X | - | - | ? |
| | - | - | 0 | + |
| | + | ? | + | + |

Figura 2.20: Operação com variáveis qualitativas

Podem-se também definir operadores qualitativos de diferença e produto. Por exemplo, considere representar o volume da água em um copo como vazio, meio-termo, cheio. Se derrarmos o conteúdo de um copo em outro, que

quantidade de água o segundo copo conterà?. Pode-se somar qualitativamente do seguinte modo:

vazio + vazio = vazio

vazio + meio-termo = meio-termo

vazio + cheio = cheio

meio-termo + meio-termo = cheio? ou meio-termo?

meio-termo + cheio = cheio? ou transbordar?

cheio + cheio = cheio + transbordar

Note que a combinação de valores qualitativos pode provocar ambiguidades.

5. Equações.

São formadas a partir de expressões e variáveis que podem ser ligadas entre si. A equação mais simples afirma que a variável y aumenta conforme aumenta a variável x . Isto nos dá uma representação abstrata da verdadeira função que relaciona x e y , por exemplo:

$$y = M^+(x)$$

6. Valores limites.

São os pontos que separam uma região de outra. Por exemplo, tem-se duas regiões + e - , o 0 viria ser um valor limite, posto que separa a região + da região - (figura 2.21).




Figura 2.21: Valores limites entre duas regiões adjacentes

7. Comportamento qualitativo.

Denota um conjunto de valores ordenado no tempo de uma variável qualitativa, i.e., um episódio.

8. Estados qualitativos.

Um estado é um único instantâneo, onde cada variável possui um valor. Há várias maneiras diferentes de formular informações sobre estados, por exemplo: no estado da figura 2.19 pode ser representado por "Chuva caindo".

9. Modelos qualitativos.

São modelos que operam sobre estados qualitativos.

10. Simulação qualitativa.

É um gerador de episódio que infere comportamentos qualitativos desde um modelo qualitativo.

Ontologias do Raciocínio Qualitativo

- Tempo

A noção mais básica de tempo é que ele é ocupado por eventos. Esses eventos ocorrem durante intervalos, intervalos contínuos de tempo. Os intervalos podem estar relacionados a outros intervalos, existem treze maneiras como dois intervalos de tempo não vazios podem estar relacionados entre si. Na seguinte figura mostra-se esses relacionamentos, na verdade são apenas sete relacionamentos distintos, mas seis deles têm seus próprios inversos [72] (figura 2.22).




Figura 2.22: Treze relacionamentos possíveis entre dois intervalos de tempo

- Espaço

Os objetos têm extensão espacial ao passo que os eventos têm extensão temporal. Podemos então tentar expandir a teoria de tempo para uma teoria

de espaço. Mas como o espaço é tridimensional, há muito mais do que treze relacionamentos espaciais entre dois objetos, dentre elas temos: “Dentro”, “Adjacente”, “Perpendicular”, “Ao-Longo”, etc.

Pode-se ver que a representação do conhecimento no raciocínio qualitativo não é tão simples. Muitos trabalhos foram desenvolvidos nesta área, mas ainda há muito para ser feito.




Figura 2.23: Representação qualitativa da pressão sistólica

O raciocínio qualitativo é útil para modelar sistemas dos quais não se tem informação completa. A forma de representação da informação qualitativa não é apropriada para ser aplicada às informações médicas em sistemas de diagnóstico clínico. Dado que, a principal dificuldade é que ela apresenta mudanças abruptas, fato que não acontece na medicina. Por exemplo, na figura 2.23, observa-se que uma pequena mudança na pressão sistólica pode levar a uma interpretação de normal a patológica, fato que nem sempre é verdade, e que a lógica nebulosa pode representar melhor (figura 2.24).




Figura 2.24: Funções de pertinência para a pressão sistólica

Neste caso, os conjuntos nebulosos permitem uma transição menos abrupta e representam melhor os conceitos clínicos. Por exemplo, tem-se uma faixa de valores $[a, b]$ onde uma pressão sistólica pertence ao conjunto nebuloso normal e ao conjunto

nebuloso hipertensão com diferentes graus de pertinência. Observe-se que a figura 2.23 pode ser considerada como funções de pertinência, onde os graus de pertinência são 1 (pertinência total) ou 0 (não pertinência), e esta é uma das razões pelas quais considera-se o raciocínio qualitativo como um caso particular do raciocínio nebuloso.

2.2 Avaliação das Formas de Raciocínio

Depois de apresentadas as formas de raciocínio impreciso e incerto, pode-se perceber que as pessoas não utilizam um único raciocínio na resolução dos problemas, elas utilizam todos eles de forma simultânea ou um depois de outro segundo as características principais do problema a resolver. Por exemplo, o médico ao fazer diagnóstico tem como dados de partida informações qualitativas, imprecisas e incertas, a partir delas ele deve chegar a uma conclusão. Que raciocínio ele utiliza?.

- Raciocínio plausível ao considerar os sintomas como evidências para formar uma conjectura (diagnóstico),
- Raciocínio probabilístico ao relacionar os sintomas com informações probabilísticas de doenças já existentes no meio,
- Raciocínio nebuloso ao considerar a imprecisão dos sintomas ou
- Raciocínio qualitativo ao avaliar informações qualitativas.

Ele pode ter utilizado uma ou mais de uma forma de raciocínio.

O interesse é saber qual deles pode ser o melhor para modelar o raciocínio clínico para diagnóstico e como se poderia ao mesmo tempo representar a imprecisão nos dados clínicos, e nesse sentido tem-se que:

- O raciocínio plausível é o que mais se aproxima do raciocínio clínico pelas características apresentadas, mas não tem mecanismos para representar a imprecisão dos dados apesar de que neste raciocínio os dados provêm de evidências as quais podem ser consideradas não somente como verdadeiras ou falsas, senão permite valores como “um pouco mais credível”, “um pouco menos credível”, e assim por diante, ou seja, elas podem ser associadas à força ou peso sob a crença em alguma evidência dada [67].

- O raciocínio probabilístico não é tão representativo do raciocínio clínico porque nem sempre o médico vai fazer avaliações sobre o paciente relacionando-o a informações probabilísticas, mas tem-se utilizado técnicas probabilísticas para representar o raciocínio clínico [80].
- O raciocínio nebuloso pode representar melhor os dados através de conjuntos nebulosos e funções de pertinência, mas as operações (max-min, max-produto, t-norma, t-conorma) com funções de pertinência para determinar o consequente da regra nebulosa não representam o raciocínio clínico.
- O raciocínio qualitativo, representa variáveis qualitativas, mas ele não tem a flexibilidade dos conjuntos nebulosos na representação da imprecisão das variáveis qualitativas. O que além de ter mudanças abruptas (fato que não ocorre na medicina) vai gerar dificuldades na operação destas. Por exemplo, ao somar duas variáveis: positiva e negativa, se elas são consideradas ao mesmo tempo grandes ou pequenas, não se tem uma única resposta correta, posto que segundo a quantidade de cada uma delas poderia ser zero, positiva ou negativa. Isto nos faz imaginar uma pequena árvore de decisão neste ponto (figura 2.25), que ocorrerá cada vez que ele não tenha uma única resposta correta.

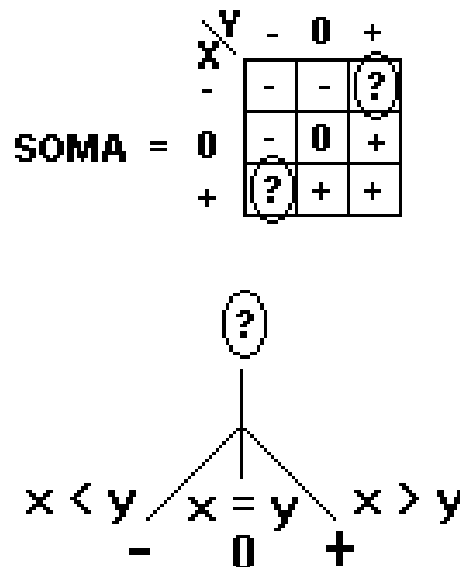


Figura 2.25: Árvores geradas ao operar duas variáveis qualitativas

Capítulo 3

Tratamento da Imprecisão e Incerteza

Uma das dificuldades no desenvolvimento de SE é o tratamento da incerteza nas informações e a imprecisão nos dados, as quais são as variáveis fundamentais no processo do raciocínio. Infelizmente, determinar a “melhor” conclusão em SE pode não ser tão fácil nem simples [32]. Deve-se ressaltar que apesar das pessoas usarem indistintamente os termos imprecisão e incerteza, para identificar dados ou informações inexatas, eles têm significados diferentes:

- Incerteza, diz-se que existe incerteza em uma informação quando não se tem certeza absoluta de ela ser verdadeira ou não. Geralmente é representado por um valor numérico que indica o **grau de certeza**, este valor pode encontrar-se no intervalo de $[0,1]$, onde 1 indica que se está certo de que o fato é verdadeiro e 0 indica que se está certo de que o fato não é verdadeiro.
- Imprecisão, (nebulosidade) ocorre quando a informação não tem seus limites definidos. Por exemplo a idade, para alguns, 25 anos é jovem, e para outros 35 anos é jovem. Isto quer dizer que não existem valores quantitativos únicos que definam o termo “jovem”. Ao contrário da incerteza, não depende do quanto se acredita se a informação é verdadeira ou não, mas é inerente aos valores linguísticos utilizados.

Pode-se dizer então que a imprecisão e incerteza são conceitos diferentes, mas os dois pertencem ao tipo de informações inexatas. Diversos métodos foram desenvolvidos para levar em consideração esses tipos de informação. Estes métodos

procuram meios para representar a imprecisão e/ou a incerteza e assim proporcionar uma inferência mais aproximada à realidade. Existem várias formas numéricas para tratar com informações inexatas, pode-se citar a probabilidade Bayesiana, os fatores de certeza, a teoria de Dempster-Shafer e a lógica nebulosa.

3.1 Probabilidades e Teorema de Bayes

A probabilidade sempre foi relacionada com a medida de eventos repetíveis de sistemas ideais. No entanto, hoje em dia se fala da probabilidade subjetiva, ela trata com eventos que não têm uma base histórica (base de dados) sob a qual se possa extrapolar. A probabilidade subjetiva é atualmente uma crença ou opinião expressa como uma probabilidade mais do que uma probabilidade baseada em medidas empíricas. As crenças e opiniões de um especialista têm um papel importante no desenvolvimento do SE.

Em SE para diagnóstico médico, deve-se aumentar âmbito dos eventos para tratar com proposições, as quais são declarações que são verdadeiras ou falsas. Por exemplo, um evento poderia ser:

$E =$ “O paciente está coberto com manchas vermelhas”

e a proposição é:

$A =$ “O paciente tem sarampo”

Dado que A é uma proposição, a probabilidade condicional:

$$P(A | E)$$

esta não é uma probabilidade no sentido clássico ou frequentista. Em vez disso, $P(A | E)$ pode ser interpretado como o **grau de crença** que A é verdadeiro, dado o evento E .

Se $P(A | E) = 1$, logo nossa crença em A é verdadeira.

Se $P(A | E) = 0$, nossa crença em A é falsa,

$0 < P(A | E) < 1$, para outros valores, isto significa que não se está inteiramente seguro que A é verdadeira ou falsa.

Da estatística, o termo **hipótese** é utilizado para alguma proposição da qual sua verdade ou falsidade não é conhecida, mas esta assegurada com a base de alguma evidência. A probabilidade condicional é logo referida como a verossimilhança, como

em

$$P(H | E) = 1$$

a qual expressa a verosimilhança da hipótese, H , baseada em alguma evidência E . Para computá-la, precisa-se levar em conta a probabilidade prévia de H e até que ponto E fornece evidências para H . Precisa-se então definir um universo que contenha um conjunto exaustivo e mutuamente exclusivo de H_i s que se está tentando discriminar a partir das evidências (dados de entrada). Seja:

$P(H_i | E)$ = probabilidade de que a hipótese H_i seja verdadeira, dada a evidência E .

$P(E | H_i)$ = probabilidade de que observaremos a evidência E , dado que a hipótese H_i é verdadeira.

$P(H_i)$ = probabilidade, a priori, de que a hipótese i seja verdadeira na ausência de qualquer evidência específica.

k = número de hipóteses possíveis.

$$P(H_i | E) = \frac{P(E | H_i) \cdot P(H_i)}{\sum_{n=1}^k P(E | H_n) \cdot P(H_n)}$$

Para usar o teorema de Bayes como base para o raciocínio sob incerteza deve-se reconhecer exatamente o que ele expressa. Quando diz $P(A | B)$, descreve-se a probabilidade condicional de A , dado que se tem uma única evidência B . Se houver outras evidências relevantes, elas deverão ser consideradas, tal é caso em SE para apoio à decisão médica. Nestes sistemas tem-se um conjunto E de evidências (sintomas) e busca-se selecionar a hipótese H_i com maior valor de probabilidade $P(H_i | E)$.

Atualmente existem “*shells*” para o desenvolvimento de SE com raciocínio probabilístico (redes Bayesianas), dentre elas tem-se o **SPIRIT** [35] e o **HUGIN** [36].

3.1.1 Dificuldades com o Método Bayesiano

Para chegar ao diagnóstico clínico, o ponto de partida inicia-se na observação dos sintomas apresentados pelo paciente, mas eles não aparecem ao mesmo tempo. Suponha-se o seguinte caso:

A : O paciente tem febre

B : O paciente tem manchas na pele

H : O paciente tem lupus

A presença de febre e manchas na pele servem como evidência em favor do lupus,

mas posteriormente poderiam-se apresentar novos sintomas que podem dar maior força à hipótese ou não. Em geral, dada uma evidência prévia e e algumas novas observações E , precisamos calcular.

$$P(H | E, e) = P(H | E) \cdot \frac{P(e | E, H)}{P(e | E)}$$

Infelizmente, em um mundo arbitrariamente complexo, o número de probabilidades conjuntas necessárias para calcular esta função cresce em $2n$ caso haja n evidências diferentes sendo consideradas.

Para tratar com um número elevado de evidências tem-se trabalhado a propagação de probabilidades através da entropia. O uso da teoria da probabilidade no desenvolvimento de SE de apoio no diagnóstico médico apresenta as seguintes dificuldades:

- A obtenção das probabilidades das hipóteses H_i e as condicionais $P(H_i | E)$ é considerado uma tarefa difícil porque as pessoas não sabem estimar probabilidades. No entanto, as estimativas necessárias de probabilidade são feitas pelo especialista a partir de seu conhecimento e experiência no domínio pesquisado (valor qualitativo de probabilidade).
- A base de conhecimento tem que ser completa. Isto é todas as evidências relevantes às hipóteses consideradas devem estar explícitas na base de conhecimento.
- Em probabilidade, parte-se do fato que as evidências são independentes. Isto nem sempre é verdadeiro no caso das doenças, posto que alguns sintomas poderiam ser evidência de outros.

Apesar destes problemas, porém, as probabilidades Bayesianas são uma base atraente para um sistema de raciocínio sob incerteza e foram desenvolvidos vários mecanismos para explorar seu potencial e, ao mesmo tempo, torná-la tratável [80].

3.2 Fatores de Certeza

Esta abordagem teve como pioneiro o sistema MYCIN [79], o qual tenta recomendar terapias apropriadas para pacientes com infecções bacteriológicas.

No MYCIN, o grau de confirmação foi originalmente definido como um fator de certeza(FC), que é a diferença entre crença e descrença Define-se então:

$$FC[H, E] = MC[H, E] - MD[H, E]$$

onde:

$FC = [H, E]$ é o fator de certeza na hipótese H dada à evidência E

$MC = [H, E]$ medida de crença em H dado E

$MD = [H, E]$ medida de descrença em H dado E

O FC é um caminho simples para combinar crença e descrença em um número. Esta combinação pode ter dois usos:

- Primeiro, o FC pode ser usado para um conjunto de hipóteses em ordem de importância. Por exemplo, se um paciente tem certos sintomas os quais sugerem diversas doenças possíveis, logo a doença com um alto FC poderia ser uma que é primeiro pesquisada pelos testes ordenados. As medidas de crença e descrença foram definidas em termos de probabilidade por:

$$MC(H, E) = \begin{cases} 1 & \text{se } P(H) = 1 \\ \frac{\max[P(H|E), P(H)] - P(H)}{\max[1, 0] - P(H)} & \text{em outros casos} \end{cases}$$

$$MD(H, E) = \begin{cases} 1 & \text{se } P(H) = 0 \\ \frac{\min[P(H|E), P(H)] - P(H)}{\min[1, 0] - P(H)} & \text{em outros casos} \end{cases}$$

O máximo de $[0, 1]$ é sempre 1 e o mínimo de $[0, 1]$ é sempre 0, mas nas igualdades acima mostradas escreveu-se as expressões explicitamente para observar a simetria entre as MC e MD .

Segundo estas definições, algumas características são mostradas na Tabela 3.1.

- Segundo, o FC indica a rede de crença em uma hipótese sob alguma evidência. Um FC positivo significa que a evidência suporta a hipótese desde que $MC > MD$. Um $FC = 1$ significa que a evidência definitivamente prova a hipótese. Um $FC = 0$ significa uma de duas possibilidades:

1. $MC = MD = 0$, as duas são zero, isto é, na realidade não existe evidência ou ela é irrelevante.
2. $MC = MD \neq 0$, as duas não são zero. A crença e descrença são igualmente fortes ou fracas. Assim a crença é cancelada pela descrença.

O FC negativo significa que a evidência favorece a negação da hipótese desde que $MC < MD$. Uma outra maneira de expressar isto é que existem mais

| Características | Valores |
|---|---|
| Variações | $0 \leq MC \leq 1$ $0 \leq MD \leq 1$ $-1 \leq FC \leq 1$ |
| Certeza das hipóteses verdadeiras $P(H E) = 1$ | $MC = 1$ $MD = 0$ $FC = 1$ |
| Certeza das hipóteses falsas $P(\neg H E) = 1$ | $MD = 0$ $MC = 1$ $FC = -1$ |
| Perda de Evidência $P(H E) = P(H)$ | $MC = 0$ $MD = 0$ $FC = 0$ |

Tabela 3.1: Algumas características de medidas de crença, descrença e fatores de certeza

razões para a descrença em uma hipótese do que para a crença nela. Por exemplo, um $FC = -70\%$ significa que a descrença é 70% maior do que a crença. Um $FC = 70\%$ significa que a crença é 70% maior do que a descrença. Estes FC , não são limitados pelos valores individuais de MC e MD , por exemplo, valores individuais diferentes levam ao mesmo valor de FC :

$$FC = 0,80 = 0,80 - 0$$

$$FC = 0,80 = 0,95 - 0,15$$

e assim por diante.

Os FC permitem ao especialista expressar uma crença sem comprometer um valor para a descrença, isto é:

$$FC(H, E) + FC(\neg H, E) = 0$$

o qual significa que se a evidência confirma uma hipótese por algum valor $FC(H | E)$, a confirmação da negação da hipótese não é $1 - FC(H | E)$. Isto é:

$$FC(H, E) + FC(\neg H, E) \neq 1$$

O fato que $FC(H | E) + FC(\neg H | E) = 0$ significa que se a evidência suporta uma hipótese reduz o suporte para a negação da hipótese por uma quantidade igual, tal que a soma é sempre zero.

Por exemplo o aluno graduar-se-á se um A é obtido no curso $FC(H, E) = 0,65$ e $FC(\neg H, E) = -0,65$ significa:

- Tem-se 65% de certeza que o aluno se graduará se obtiver um A no curso
- Tem-se -65% de certeza que o aluno não se graduará se obtiver um A no curso

3.2.1 Avaliando com Fatores de Certeza

A definição original dos fatores de certeza foi:

$$FC = MC - MD$$

mas nessa expressão encontraram-se dificuldades, por exemplo, suponha-se que dez partes confirmam a evidência gerando $MC=0,999$ e uma parte desconfirma a evidência gerando $MD=0,799$, avaliando-se com a expressão anterior tem-se:

$$FC = 0,999 - 0,799 = 0,2$$

Como no MYCIN o FC de um antecedente da regra deveria ser maior que 0.2 para que esse antecedente seja considerado verdadeiro e ativasse a regra, pode-se observar que no caso do exemplo isto não aconteceria. O valor limiar de 0,2 foi feito como um caminho “*ad hoc*” de minimizar a ativação de regras que sugerem fracamente uma hipótese. A não existência deste valor limiar poderia gerar a ativação de muitas regras e reduzir a eficiência do sistema.

Assim, o FC no MYCIN foi mudado do seguinte modo [32]:

$$FC = \frac{MC - MD}{1 - \min(MC, MD)}$$

para suavizar o efeito de uma parte que desconfirma a evidência afete a muitas partes que confirmam a evidência. Avaliando no exemplo anterior tem-se:

$$FC = \frac{0,999 - 0,799}{1 - \min(0,999)(0,799)} = 0,995$$

resultado bastante diferente do obtido anteriormente, garantindo neste caso que a regra será ativada.

| Evidência, E | Certeza do Antecedente |
|----------------|--------------------------------|
| E_1 e E_2 | $\min[FC(H, E_1), FC(H, E_2)]$ |
| E_1 ou E_2 | $\max[FC(H, E_1), FC(H, E_2)]$ |
| $\neg E$ | $-FC(H, E)$ |

Tabela 3.2: Regras do MYCIN para combinação das evidências dos antecedentes de expressões elementais

Os métodos do MYCIN para combinação das evidências no antecedente de uma regra são mostradas na Tabela 3.2.

Por exemplo:

$$E = (E_1 \wedge E_2 \wedge E_3) \vee (E_4 \wedge \neg E_5)$$

$$E = \max[\min(E_1, E_2, E_3), \min(E_4, -E_5)]$$

A fórmula fundamental para o FC de uma regra “Se E então H ” está dado pela fórmula:

$$FC(H, e) = FC(H, E)FC(E, e)$$

onde:

$FC(E, e)$ é o fator de certeza da evidência E constituindo o antecedente da regra baseada na evidência incerta e .

$FC(H, E)$ é o fator de certeza da hipótese supondo que a evidência é conhecida com certeza, quando $FC(E, e) = 1$.

$FC(H, e)$ é o fator de certeza da hipótese baseada na incerteza da evidência e .

Assim, se todas as evidências no antecedente são conhecidas com certeza, a fórmula para o fator de certeza da hipótese é:

$$FC(H, e) = FC(H, E)$$

desde que $FC(E, e) = 1$

Por exemplo, tem-se a seguinte regra:

Se $A \wedge B \wedge C \rightarrow D$ com uma evidência de (0,7)

onde o fator de certeza da hipótese sobre evidência certa é:

$$FC(H, E) = FC(H, E_1 \cap E_2 \cap E_3) = 0,7$$

este é também chamado de fator de atenuação.

O fator de atenuação é baseado na suposição que todas as evidências, E_1 , E_2 e E_3 , são conhecidas com certeza, isto é:

$$FC(E_1, e) = FC(E_2, e) = FC(E_3, e) = 1$$

onde e é a evidência observada que dirige a conclusão que as E_i são conhecidas com certeza.

Suponha-se que,

$$FC(E_1, e) = 0,5$$

$$FC(E_2, e) = 0,6$$

$$FC(E_3, e) = 0,3$$

logo

$$FC(E, e) = FC(E_1 \cap E_2 \cap E_3, e)$$

$$FC(E, e) = \min[FC(E_1, e), FC(E_2, e), FC(E_3, e)]$$

$$FC(E, e) = 0,3$$

O fator de certeza da conclusão é:

$$FC(H, E) = FC(H, E)FC(E, e)$$

$$FC(H, E) = (0,7)(0,3) = 0,21$$

Quando se tem uma outra regra que também conclui a mesma hipótese, mas com um diferente fator de certeza; o fator de certeza de regras concluindo a mesma hipótese é calculada pela **função combinação** para fatores de certeza definida como:

$$FC_{\text{combinação}}((FC_1, FC_2)) = \begin{cases} FC_1 + FC_2(1 - FC_1) & \text{se as duas são } > 0 \\ \frac{FC_1 + FC_2}{1 - \min(|FC_1|, |FC_2|)} & \text{se uma é } < 0 \\ FC_1 + FC_2(1 + FC_1) & \text{se as duas são } < 0 \end{cases}$$

No exemplo, se o $FC_2 = 0,5$, logo a certeza combinada usando as expressões anteriores seria:

$$FC_{\text{combinação}}(0,21)(0,5) = 0,21 + 0,5(1 - 0,21) = 0,605$$

suponha-se que o $FC_3 = -0,4$ temos:

$$FC_{\text{combinação}}(0,605)(-0,4) = \frac{0,605 - 0,4}{1 - \min(|0,605|, |-0,4|)} = 0,34$$



Figura 3.1: Cálculo do fator de certeza combinado de duas regras com a mesma hipótese baseado na evidência incerta

A fórmula de $FC_{combinação}$ preserva a comutatividade da evidência. Isto é

$$FC_{combinação}(X, Y) = FC_{combinação}(Y, X)$$

A figura 3.1 mostra o cálculo de fatores de certeza combinado de duas regras com a mesma hipótese baseada na evidência incerta.

3.2.2 Dificuldades com os Fatores de Certeza

Ainda que o MYCIN tenha tido sucesso em diagnóstico, existem dificuldades com os fundamentos teóricos dos fatores de certeza. Enquanto que os FC tem alguma base na teoria da probabilidade e a teoria da confirmação, eles também foram parcialmente “*ad hoc*”. A maior vantagem dos FC foi a simples computação pela qual a incerteza seria propagada no sistema. O FC foram fáceis de compreender e separaram claramente crença de descrença.

No entanto, existem problemas com os FC. Um deles é que os valores de FC poderiam ser o oposto da probabilidade condicional. Por exemplo, tem-se que:

$$P(H_1) = 0,8$$

$$P(H_1 | E) = 0,9$$

$$P(H_2) = 0,2$$

$$P(H_2 | E) = 0,8$$

depois, calculando o FC para as duas hipóteses, tem-se:

$$FC(H_1, E) = 0,5$$

$$FC(H_2, E) = 0,75$$

Desde que um propósito dos FC é posicionar hipóteses em termos de diagnósticos verossímeis, esta é uma contradição para uma doença que tem uma alta probabilidade condicional $P(H | E)$ e ainda tem um baixo fator de certeza, $FC(H, E)$.

O segundo maior problema com FC é que, em geral:

$$P(H | e) \neq P(H | h_i)P(h_i | e)$$

onde h_i é alguma hipótese intermediária baseada na evidência e , e ainda o fator de certeza de duas regras em uma cadeia de inferência é calculada como probabilidades independentes por:

$$FC(H, e) = FC(H, h_i)FC(h_i, e)$$

A fórmula acima mostrada é verdadeira somente no caso especial que a população com propriedades H é contida na população com propriedades h_i , e que está contida na população com propriedades e . O sucesso do MYCIN a despeito destes problemas é provavelmente devido às pequenas cadeias de inferências e a hipóteses simples. Poderiam existir problemas reais ao aplicar fatores de certeza a outros domínios que não tivessem cadeias de inferência pequenas nem hipóteses simples [32].

3.3 A Teoria de Dempster-Shafer

Esta baseado no o trabalho feito originalmente por Dempster, que tentou modelar a incerteza por uma faixa de probabilidades mais do que um simples número probabilístico [32]. Shafer estendeu e refinou o trabalho de Dempster num livro publicado em 1976 chamado “*A Mathematical Theory of Evidence*” [78].

A teoria de Dempster-Shafer supõe que existe um conjunto fixo de elementos mutuamente exclusivos e exaustivos, chamado “meio” e simbolizado por θ exemplo: $\theta = \{\theta_1, \theta_2, \theta_3, \dots, \theta_n\}$. O meio é um termo usado para referir-se ao universo de discurso em teoria de conjuntos. O meio é o conjunto de objetos que são de interesse . Exemplo: $\theta = \{\text{avião}, \text{submarino}, \text{trem}, \text{ônibus}\}$. Note que todos os elementos são mutuamente exclusivos. Por exemplo, um trem não é um avião. Um caminho de pensar sobre θ é em termos de perguntas e respostas, à pergunta “*Qual deles é transporte terrestre?*” a resposta seria o subconjunto de θ :

$$\{\theta_3, \theta_4\} = \{\text{trem}, \text{ônibus}\}.$$

Assim, cada subconjunto de θ pode ser interpretado como uma possível resposta a uma pergunta. Desde que os elementos são mutuamente exclusivos e o meio exaustivo, pode existir somente um subconjunto com a resposta correta. Mas nem todas as perguntas podem ser significativas ou relevantes. É importante perceber que todos os subconjuntos do meio são respostas possivelmente válidas em seu universo de discurso.

3.3.1 A Função *Mass* (m)

A função m é definida para os elementos de θ e todos seus subconjuntos (incluindo subconjuntos unitários que correspondem a elementos isolados). Onde m é um valor que mede a quantidade de crença corretamente atribuída a um subconjunto de θ . Se θ contém n elementos, então há $2n$ subconjuntos de θ . Aparentemente é impraticável lidar com $2n$ valores, mas ocorre que muitos dos subconjuntos nunca terão de ser considerados, porque não têm significado para o domínio do problema (e portanto o valor de m a eles associado será 0).

A teoria de Dempster-Shafer não força crenças pelo desconhecimento de uma hipótese. Em vez disso a quantidade é designada somente aos subconjuntos do meio aos quais deseja-se designar crença. Qualquer crença que não é designada a um subconjunto específico é considerada não crença ou sem crença e somente associada com o meio θ . Seja:

$$\theta = \{A, B, C\}$$

suponha-se que feita uma pergunta sobre o conjunto θ surge uma evidência de 0,7 que a resposta encontra-se sobre os elementos A e C , esta quantidade designa o sub-conjunto $\{A, C\}$ e pode ser expressa como:

$$m_1(\{A, C\}) = 0,7$$

onde m_1 representa a quantidade de evidência sobre os elementos A e C .

O restante da crença é designada ao meio:

$$m_1(\theta) = 1 - 0,7 = 0,3$$

Esta é uma grande diferença com a Teoria da Probabilidade, a qual poderia supor que:

$$P(\{A, B\}) = 0,7$$

$$P(\neg\{A, B\}) = 0,3$$

É importante perceber que a designação de 0,3 ao meio θ não designa nenhum valor aos subconjuntos de θ ainda que estes subconjuntos incluam $\{A, B, C\}$, $\{A, C\}$, $\{B, C\}$, $\{A\}$, $\{B\}$ e $\{C\}$. Na Tabela 3.3 mostra-se as comparações entre a probabilidade e a teoria de Dempster-Shafer

3.3.2 Combinando evidências

Vejamos um exemplo: inicia-se com um universo exaustivo de hipóteses mutuamente exclusivas. Este universo será chamado de “estrutura de discernimento”,

| Teoria Dempster-Shafer | Teoria da Probabilidade |
|---|-------------------------|
| $m(\theta)$ não tem que ser 1 | $\sum_i P_i = 1$ |
| Se $X \subseteq Y$ não necessariamente $m(X) \leq m(Y)$ | $P(X) \leq P(Y)$ |
| Não precisa de relações entre $m(X)$ e $m(X')$ | $P(X) + P(\neg X) = 1$ |

Tabela 3.3: Comparações entre a teoria Dempster-Shafer e a teoria da probabilidade

denotada por θ :

$$\theta = \{artrite, lupus, poliarterite, gota\}$$

a meta é anexar alguma medida de crença aos elementos de θ . Nem todas as evidências sustentam diretamente elementos isolados. Em geral elas sustentam grupos de elementos (subconjuntos de θ). Por exemplo: febre pode sustentar {artrite, lupus} e erupções em asa de borboleta sustentam {lupus}. Como os elementos de θ são mutuamente exclusivos, as evidências em favor de alguns podem afetar a crença nos outros. Inicialmente não se tem nenhuma informação sobre como escolher entre as quatro hipóteses, então define-se:

$$m(\theta) = 1$$

o que quer dizer que todos os outros valores de θ são 0. O valor real pode ser um dos elementos artrite (A), lupus (L), poliarterite (P), gota (G), mas não se tem informações que permitam atribuir crença a algum deles, só temos a certeza de que a resposta está em algum lugar desse conjunto.

Supõe-se que, surjam evidências que sugiram (crença de 0,6) que o diagnóstico correto está no subconjunto $\{A, L\}$ de θ e é representado por m_1 :

$$m_1(\{A, L\}) = 0,6$$

$$m_1(\theta) = 0,4$$

e uma outra evidência sugere (crença de 0,8) que o diagnóstico correto está no subconjunto $\{L\}$ de θ e é representado por m_2 :

$$m_2(\{L\}) = 0,8$$

$$m_2(\theta) = 0,2$$

Estas evidências podem ser combinadas usando a forma de **Combinação de Regras de Dempster** para produzir a combinação de m ,

$$m_1 \oplus m_2 = \sum_{X \cap Y = Z} m_1(X)m_2(Y)$$

onde a soma estende-se sobre todos os elementos nos quais a interseção $X \cap Y = Z$. O operador \oplus denota a soma ortogonal ou soma direta a qual é calculada pelo produto das interseções m do lado direito da regra. Na Tabela 3.4 mostra-se os m e os produtos das interseções.

| | | |
|-----------------------|--------------------|---------------------|
| Valores de m | $m_2(\{L\}) = 0,8$ | $m_2(\theta) = 0,2$ |
| $m_1(\{A, L\}) = 0,6$ | $\{L\} = 0,48$ | $\{A, L\} = 0,12$ |
| $m_1(\theta) = 0,4$ | $\{L\} = 0,32$ | $(\theta) = 0,08$ |

Tabela 3.4: Confirmação de evidências

Depois que os produtos m foram calculados, em seguida de acordo com a Regra de Dempster os produtos sobre as interseções dos conjuntos comuns são somados:

$$m_3(\{L\}) = m_1 \oplus m_2(\{L\}) = 0,48 + 0,32 = 0,80 \text{ de crença para o Lupus}$$

$$m_3(\{A, L\}) = m_1 \oplus m_2(\{A, L\}) = 0,12 \text{ de crença para a Artrite ou Lupus}$$

$$m_3(\{\theta\}) = m_1 \oplus m_2(\theta) = 0,08 \text{ de não crença ou sem crença}$$

3.3.3 Normalização de Crenças

Supõe-se que se tenha uma terceira evidência conflitante:

$$m_3(\{P\}) = 0,95 \text{ e } m(\theta) = 0,05$$

A Tabela 3.5 mostra os cálculos:

| | | | |
|----------------------|-------------------------------|-----------------------------------|---------------------------------|
| Valores de m | $m_1 \oplus m_2(\{L\}) = 0,8$ | $m_1 \oplus m_2(\{A, L\}) = 0,12$ | $m_1 \oplus m_2(\theta) = 0,08$ |
| $m_3(\{P\}) = 0,95$ | $\{\emptyset\} = 0,76$ | $\{\emptyset\} = 0,114$ | $\{P\} = 0,076$ |
| $m_3(\theta) = 0,05$ | $\{L\} = 0,04$ | $\{A, L\} = 0,006$ | $(\theta) = 0,004$ |

Tabela 3.5: Combinação da evidência adicional m_3

O conjunto nulo, $\{\emptyset\}$, ocorre devido a que $\{P\}$ e $\{L\}$ não têm elementos comuns, também não ocorre entre $\{P\}$ e $\{A, L\}$. Assim:

$$m_1 \oplus m_2 \oplus m_3(\{P\}) = 0,076$$

$$m_1 \oplus m_2 \oplus m_3(\{L\}) = 0,04$$

$$m_1 \oplus m_2 \oplus m_3(\{A, L\}) = 0,006$$

$$m_1 \oplus m_2 \oplus m_3(\theta) = 0,004$$

$$m_1 \oplus m_2 \oplus m_3(\{\emptyset\}) = 0, \text{ pela definição do conjunto nulo.}$$

Neste caso a soma de todos os m é menor do que 1, isto é,

$$\sum m_1 \oplus m_2 \oplus m_3(X) = 0,076 + 0,04 + 0,006 + 0,004 = 0,126$$

Uma soma de 1 é requerida desde que as evidências combinadas, $m_1 \oplus m_2 \oplus m_3$, seja um m válido e a soma sobre todos os elementos foco deve ser 1. O fato de que a soma é menor que 1 apresenta um problema.

A solução a este problema é a **normalização** de todos os elementos focais pela divisão de cada elemento foco por:

$$1 - k$$

onde k é definido para qualquer conjunto X e Y como:

$$k = \sum_{X \cap Y = \{\emptyset\}} m_1(X)m_2(Y)$$

No exemplo,

$$k = 0,76 + 0,114 = 0,874$$

e

$$1 - k = 1 - 0,874 = 0,126$$

Do que se obtém os seguintes valores normalizados:

$$m_1 \oplus m_2 \oplus m_3(\{P\}) = 0,603$$

$$m_1 \oplus m_2 \oplus m_3(\{L\}) = 0,317$$

$$m_1 \oplus m_2 \oplus m_3(\{A, L\}) = 0,0476$$

$$m_1 \oplus m_2 \oplus m_3(\theta) = 0,0031$$

Onde pode-se notar que a evidência de $\{P\}$ prejudicou a crença em $\{L\}$, o que de fato era esperado.

3.3.4 Dificuldades com a Teoria de Dempster-Shafer

Uma dificuldade com a teoria de Dempster-Shafer ocorre com a normalização e que poderia levar a resultados opostos as nossas expectativas. O problema com a normalização, é que se ignora a crença de que o objeto considerado não existe. Um exemplo citado por Zadeh é o da crença de dois médicos, A e B , em uma doença de

um paciente. As crenças no problema do paciente são como segue.

$$m_A(\text{meningite}) = 0,99$$

$$m_A(\text{tumor cerebral}) = 0,01$$

$$m_B(\text{traumatismo}) = 0,99$$

$$m_B(\text{tumor cerebral}) = 0,01$$

Note que ambos médicos acham que existe muito pouca chance de tumor cerebral (0,01), mas diferem grandemente no problema principal. A regra Dempster de combinação de crenças dá 1 para o tumor cerebral. Este resultado é muito inesperado e contra nossa intuição, já que ambos médicos estiveram de acordo que o tumor cerebral era muito improvável.

3.4 Métodos Nebulosos

A lógica nebulosa está principalmente envolvida com quantificadores e raciocínio utilizando linguagem natural na qual as palavras tem significados imprecisos, tais como: *muito, um pouco, quente, perigoso, alto*, e assim por diante.

3.4.1 Lógica nebulosa e Linguagem natural

O meio comumente utilizado para representar quais objetos pertencem a um conjunto é em termos de sua **função característica**. Se um objeto é um elemento de um conjunto, então sua função característica é 1. Se um objeto não é um elemento de um conjunto, então sua função característica é 0. Isto é representado pela seguinte expressão:

$$\mu_A(x) = \begin{cases} 1 & \text{se } x \text{ é um elemento do conjunto } A \\ 0 & \text{se } x \text{ não é um elemento do conjunto } A \end{cases}$$

onde os objetos x são elementos de algum universo X .

A função característica pode ser representada pela seguinte expressão:

$$\mu_A(x) : x \rightarrow \{0, 1\}$$

a qual estabelece que a função característica mapeia um conjunto universal X formado por 0 e 1. Esta definição simples expressa o conceito “clássico” onde, um objeto pertence ou não pertence a um conjunto. Os conjuntos aos quais aplica-se esta

definição são chamados de “conjuntos abruptos” (“*conjuntos crisp*”) em contraste aos conjuntos nebulosos. Este tipo de pensamento data desde a visão Aristoteliana de lógica bivalente ou lógica de dois valores, na qual verdadeiro e falso são as únicas possibilidades. O problema com a lógica bivalente é que se vive em um mundo analógico e não digital. No mundo real, os pensamentos não são geralmente em um estado ou em outro, isto somente ocorre na arquitetura dos computadores digitais que utilizam a lógica digital bivalente. Enquanto que a teoria nebulosa e sistemas de redes neurais representam melhor o mundo real. Em lógica nebulosa, um objeto pode pertencer parcialmente a um conjunto. O grau de pertinência em um conjunto nebuloso é medido pela generalização de uma função característica chamada **função de pertinência** e definida por:

$$\mu_A(x) : x \rightarrow [0, 1]$$

Esta função de pertinência mapeia X no domínio dos números reais definido no intervalo desde 0 até 1, inclusive. A diferença da definição anterior, onde sua função característica somente permitia dois únicos valores ou 0 ou 1. A função de pertinência é um número real, definido por:

$$0 \leq \mu_A \leq 1$$

onde 0 significa não pertinência e 1 significa pertinência total ao conjunto. Um valor particular qualquer como 0.4, é chamado **grau de pertinência** de um elemento X a um conjunto A .

Os conceitos de conjuntos nebulosos são utilizados comumente em linguagem natural, tais como:

“O *mal estar* é frequente”

“A *febre* é alta”

“Se a *dor* é muito forte, dê um antiespasmódico”

onde as palavras em itálico referem-se a conjuntos nebulosos e quantificadores. Todos estes conjuntos nebulosos e quantificadores podem ser representados e operados em teoria nebulosa.

Em linguagem natural, os termos **vago** e **nebuloso** são às vezes usados como sinônimos, embora exista uma diferença grande entre estes termos no contexto da teoria nebulosa. Brevemente:

- O termo **vago** é utilizado no sentido de informação incompleta. Por exemplo, “*Pedro está em algum lugar*” é vago, não se fornece suficiente informação para uma decisão. Uma proposição como: “*Ele é alto*” pode ser vago se não se

sabe a quem se refere o pronome ele. Existe também graus de vaguidade, a frase “*Mario é alto*” é menos vago do que “*Ele é alto*”, mas ainda continua vago se não se souber quem é Mario.

- O termo **nebuloso** é utilizado para indicar que as características dos objetos não tem um limite definido. Uma proposição nebulosa contém palavras tais como **generoso**, que é identificada como um conjunto nebuloso “Generoso”. A proposição “*Claudia é generosa*” em lógica bivalente tem duas possibilidades ou é verdadeira ou é falsa, a mesma proposição em lógica nebulosa pode ter graus de verdade. Isto é ela pode ser *um pouco verdadeira, às vezes verdadeira, bastante verdadeira, muitíssimo verdadeira*, e assim por diante.

Um valor de verdade nebulosa é chamada **qualificador nebuloso**, e pode ser utilizado como um conjunto nebuloso ou para modificar um conjunto nebuloso. A diferença é que as proposições abruptas não permitem ter quantificadores, enquanto as proposições nebulosas podem ter **quantificadores nebulosos**, tais como: *poucos, muitos, usualmente*, e assim por diante, sem diferença entre declarações e proposições como no caso clássico.

3.4.2 Representação de Funções Padrões

Para ilustrar o conceito de conjunto nebuloso, considere o seguinte exemplo:

“ *Paulo é alto* ”

Se a pessoa é um adulto, logo uma altura de 2 metros pode ser considerada tendo uma função de pertinência 1 e qualquer altura menor de 1,50 metros não é considerado no conjunto nebuloso ALTO e sua função de pertinência é 0. Entre 1,50 e 2 metros, a função de pertinência incrementa monotonicamente com a altura (figura 3.2).

Esta função de pertinência particular é somente uma de muitas possíveis funções. As funções de pertinência serão diferentes para jogadores de basquete e jôqueis. Por exemplo um jôquei com uma altura de 1,50 m é considerado alto, enquanto que um jogador de basquete com a mesma altura seria considerado baixo.

Intuitivamente, as funções de pertinência para um grupo de pessoas pode ser formada em termos de suas opiniões, um grupo de opiniões. Suponha-se que se perguntou a um grupo de pessoas sobre o valor mínimo para a palavra “alto” e ninguém poderia dizer que alguém abaixo de 1,50 metros é alto, da mesma maneira que nenhum poderia dizer que alguém de 2 metros ou acima desse valor é baixo. Entre

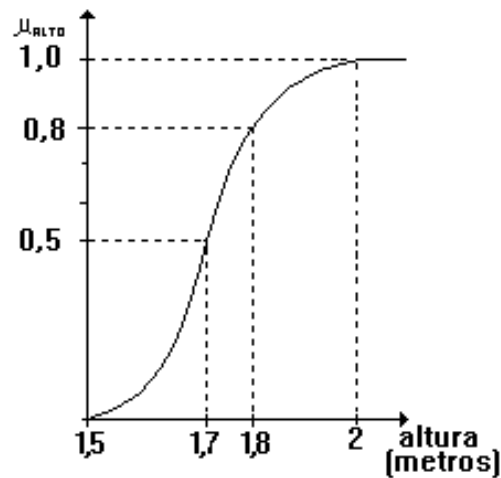


Figura 3.2: Uma função de pertinência para o conjunto nebuloso “Alto”

1,50 e 2 metros, a porcentagem de pessoas que concordaram com o que constitui a palavra “alto” é representado pela figura 3.2. Observando os pontos de interseção, pode-se dizer que 50% concordaram que alguém de 1,7 metros de altura ou acima dele é alto, 80% concordou que alguém de 1,8 metros de altura ou acima dele é alto.

É importante perceber que, embora no exemplo anterior se considera um conjunto de opiniões de um grupo, a função de pertinência não é uma distribuição de frequência.


Frequentemente, para descrever uma função de pertinência é útil utilizar um conjunto de funções padrões S , Π , Z , Triangular e Trapezoidal.

A função S

É uma função matemática que está definida por:

$$S(x; \alpha, \beta, \gamma) = \begin{cases} 0 & \text{para } x < \alpha \\ 2\left(\frac{x-\alpha}{\gamma-\alpha}\right)^2 & \text{para } \alpha \leq x \leq \beta \\ 1 - 2\left(\frac{x-\gamma}{\gamma-\alpha}\right)^2 & \text{para } \beta < x \leq \gamma \\ 1 & \text{para } x > \gamma \end{cases}$$


aqui, α, β, γ são parâmetros que podem ser ajustados para adequar os dados de pertinência desejados (figura 3.3).

Figura 3.3: A função de pertinência S

A função Z

É uma função matemática que está definida por (figura 3.4):

$$Z(x; \alpha, \beta, \gamma) = 1 - S(x; \alpha, \beta, \gamma)$$

Figura 3.4: A função de pertinência Z

A função Π

É uma função matemática que está definida por:

$$\Pi(x; \beta, \gamma) = \begin{cases} S(x; \gamma - \beta, \gamma - \beta/2, \gamma) & \text{para } x \leq \gamma \\ 1 - S(x; \gamma, \gamma + \beta/2, \gamma + \beta) & \text{para } x \geq \gamma \end{cases}$$

β, γ são parâmetros que podem ser ajustados para adequar os dados de pertinência desejados (figura 3.5).




Figura 3.5: A função de pertinência II

A função Triangular

É uma função matemática que está definida por:

$$f(x; \alpha, \beta, \delta) = \begin{cases} 0 & \text{para } x < \alpha \text{ e } x > \delta \\ \left(\frac{x-\alpha}{\beta-\alpha}\right) & \text{para } \alpha \leq x < \beta \\ 1 & \text{para } x = \beta \\ \left(\frac{x-\delta}{\beta-\delta}\right) & \text{para } \beta < x \leq \delta \end{cases}$$

aqui, α, β, δ são parâmetros que podem ser ajustados para adequar os dados de pertinência desejados (figura 3.6).




Figura 3.6: A função de pertinência Triangular

A função Trapezoidal

É uma função matemática que está definida por:

$$f(x; \alpha, \beta, \gamma, \delta) = \begin{cases} 0 & \text{para } x < \alpha \text{ e } x > \delta \\ \left(\frac{x-\alpha}{\beta-\alpha}\right) & \text{para } \alpha \leq x < \beta \\ 1 & \text{para } \beta \leq x \leq \gamma \\ \left(\frac{x-\delta}{\gamma-\delta}\right) & \text{para } \gamma < x \leq \delta \end{cases}$$

aqui, $\alpha, \beta, \gamma, \delta$ são parâmetros que podem ser ajustados para adequar os dados de pertinência desejados (figura 3.7).




Figura 3.7: A função de pertinência Trapezoidal

3.4.3 Variáveis Linguísticas

Uma aplicação importante dos conjuntos nebulosos está em avaliar variáveis linguísticas. O objetivo é calcular com declarações em linguagem natural de maneira análoga ao caminho com que a lógica clássica calcula com declarações lógicas. Os conjuntos nebulosos e as variáveis linguísticas podem ser utilizadas para quantificar o significado da linguagem natural, a qual pode logo ser manipulada. Às variáveis linguísticas são designados valores, os quais são palavras, frases ou declarações em um linguagem natural ou artificial. Na tabela 3.6 mostra-se algumas variáveis linguísticas e os valores típicos que poderiam ser designados a eles, e a figura 3.8 mostra as funções de pertinência relacionadas à variável linguística “estatura”.

As variáveis linguísticas são comumente utilizadas em regras heurísticas. Embora, as variáveis possam ser significativas, como mostra-se na tabela 3.7.




Figura 3.8: Funções de pertinência para os valores típicos da variável linguística “estatura”

| Variável Linguística | Valores Típicos |
|----------------------|--|
| estatura | anão, baixo, média, alto, gigante |
| etapa da vida | nenem, criança, adolescente, adulto, idoso |
| cor | vermelho, azul, verde, amarelo |

Tabela 3.6: Variáveis linguísticas e seus valores típicos

3.4.4 Sistemas de Lógica Nebulosa

Assim como a lógica clássica é a base dos SE convencionais, a lógica nebulosa é a base dos SE nebulosos. Além de tratar com incerteza, os SE nebulosos são também capazes de modelar o raciocínio de senso comum, o qual é muito difícil para os sistemas convencionais.

Uma limitação básica da lógica clássica é sua restrição a dois valores, verdadeiro ou falso. Esta restrição tem vantagens e desvantagens. A principal vantagem é que os sistemas baseados na lógica de dois valores são fáceis de modelar dedutivamente, com as inferências sendo exatas. Enquanto que sua desvantagem é que muito poucas

| |
|--|
| SE a imagem da TV está muito escura ENTÃO aumentar o brilho |
| SE a água está muito quente ENTÃO acrescentar um pouco de gelo |
| SE a pressão é muito alta ENTÃO abrir a válvula de emergência |

Tabela 3.7: Algumas regras heurísticas envolvendo variáveis linguísticas significativas

coisas no mundo real são realmente de dois valores.

A lógica como base para o raciocínio pode ser distinguida essencialmente por três tópicos neutros (contexto independente): valores de verdade, vocabulário (operadores) e procedimentos de raciocínio (por exemplo: tautologias, silogismos). Na lógica booleana os valores de verdade podem ser verdadeiro (1) ou falso (0) e pelos significados destes valores de verdade o operador é definido via tabelas de verdade. Considere-se duas declarações, A e B , cada uma delas pode ser V (1) ou F (0), pode-se então construir a seguinte tabela de verdade (ver tabela 3.8):

| A | B | \wedge | \vee | \Rightarrow | \Leftrightarrow |
|-----|-----|----------|--------|---------------|-------------------|
| 1 | 1 | 1 | 1 | 1 | 1 |
| 1 | 0 | 0 | 1 | 0 | 0 |
| 0 | 1 | 0 | 1 | 1 | 0 |
| 0 | 0 | 0 | 0 | 1 | 1 |

Tabela 3.8: Tabela de verdade para duas declarações e quatro operadores

Existem $((2)^2)^2 = 16$ tabelas de verdade, cada uma delas definida por um operador. Na tabela 3.8 mostram-se apenas quatro **operadores** aos quais não é difícil designar significados, mas se tem dificuldade ao interpretar o restante dos outros operadores em termos de linguagem natural. Com mais de três variáveis o valor semântico do operador é ainda de mais difícil compreensão, sendo geralmente expressa por operadores binários mais simples.

Até aqui foi suposto que cada declaração A e B , poderia ser claramente classificada com V ou F . Se isto não fosse mais verdadeiro, logo **valores de verdade** adicionais tais como, “não decidido” ou alguma coisa parecida, pode e **deve** ser introduzida. Isto leva a existência de sistemas de lógica de multivalores. Mas pode-se induzir que o problema de interpretação dos operadores incrementa-se, para só duas declarações e três valores de verdade teriam-se $((3)^3)^2 = 729$ tabelas de verdade, a unicidade de interpretação de tabelas de verdade, as quais são convenientes em lógica booleana, desaparece.

O **procedimento de raciocínio** é geralmente baseado em tautologias tais como:

$$\textit{ModusPonens}(A \wedge (A \Rightarrow B)) \Rightarrow B$$

A tautologia obviamente depende do caráter da frase, o tipo de valor permitido, e a

definição de operadores; e elas supõem, por exemplo que todas as premissas, “(As)”, contidas em uma tautologia são idênticas. São estas suposições, as que não necessariamente refletem o mundo real, feitas na lógica bivalente que são gradativamente descontraídas na lógica nebulosa e no raciocínio plausível [93].

Sistemas nebulosos baseados em regras




Figura 3.9: Estrutura básica de um sistema nebuloso

A figura 3.9 mostra a estrutura básica de um sistema nebuloso baseado em regras. O primeiro passo no processo consiste em pegar um valor abrupto de entrada e combiná-lo com a função de pertinência definida anteriormente e armazenada no sistema para produzir uma entrada nebulosa. Estas funções de pertinência podem ser S , Z , Π , triangular, trapezoidal ou singletão. Deve-se ressaltar que as funções triangular e trapezoidal são as mais utilizadas, embora outras formas sejam mais representativas de fenômenos de ocorrência natural, elas requerem equações mais complicadas para ser representadas. Por exemplo, seja um sistema que vai estimar a quantidade de anestesia numa operação cirúrgica. Considerando a pressão sistólica do paciente tem-se as funções de pertinência (figura 3.10):




Figura 3.10: Funções de pertinência para a pressão sistólica

Onde MB: muito baixa, B: baixa, PB: um pouco baixa, N: normal, PA: um pouco alta, A: alta, MA: muito alta.

O primeiro passo no processo envolve pegar um valor abrupto da entrada e combiná-lo com a função de pertinência definida e armazenada no sistema para produzir uma entrada nebulosa, por exemplo, seja um valor de pressão sistólica de 100 mmHg, no processo de nebulização ele vai ter valores nebulosos de pertinência aos conjuntos Baixo e Pouco Baixo. Logo o processador nebuloso utiliza regras linguísticas para determinar a resposta a um conjunto de valores de entrada estabelecidas. Aplica as regras nas entradas nebulosas geradas na nebulização, logo avalia cada regra com as entradas que foram geradas na nebulização. As regras nebulosas são geralmente do tipo “Se - então” que descrevem a ação a tomar em resposta a várias entradas nebulosas. Na tabela 3.9 apresentam-se as regras para estimar a quantidade de anestesia numa operação cirúrgica [61], baseados em dados de pressão sistólica.

| Pressão sistólica um minuto antes | Pressão sistólica atual | | | | | | |
|--------------------------------------|-------------------------|-------|----------------|--------|---------------|------|---------------|
| | Muito baixa | Baixa | Pouco baixa | Normal | Pouco alta | Alta | Muito alta |
| Muito baixa | DB | DB | IP | IM | IB | IB | IB |
| Baixa | DB | DB | ZO | IP | IM | IB | IB |
| Pouco baixa | DB | DM | DP | IP | IP | IM | IB |
| Normal | DB | DM | DP | ZO | IP | IM | IB |
| Pouco alta | DB | DM | DM | DP | IP | IM | IB |
| alta | DB | DB | DM | DP | ZO | IM | IB |
| Muito alta | DB | DB | DB | DM | DM | IP | IB |

Tabela 3.9: Tabela de regras de controle nebuloso para a pressão sistólica

Onde I (incrementar), D (diminuir), ZO (zero), P(pouco)= $\pm 6\mu\text{g}/\text{kg}/\text{min}$, M(médio)= $\pm 12\mu\text{g}/\text{kg}/\text{min}$ e B(bastante)= $\pm 18\mu\text{g}/\text{kg}/\text{min}$. A taxa de infusão é de 0-30 mg/kg/min.

Suponha-se que a pressão sistólica (PS) um minuto antes foi de 140 e a atual de 120, na tabela observa-se que se ativam as regras $R^{4,3}$, $R^{4,4}$, $R^{5,3}$ e $R^{5,4}$, o passo seguinte no processo é determinar o grau de verdade de cada antecedente utilizando a nebulização, uma vez que o grau de verdade do antecedente foi determinado, acha-se o grau de verdade para cada regra. Como os antecedentes estão ligados com o operador “e” para obter o peso da regra utiliza-se o operador nebuloso “min” [42]: Se PS um minuto antes 0,9 e PS atual 0,8 então DP com 0,8

Se PS um minuto antes 0,9 e PS atual 0,5 então ZO com 0,5

Se PS um minuto antes 0,4 e PS atual 0,8 então DM com 0,4

Se PS um minuto antes 0,4 e PS atual 0,5 então DP com 0,4

O passo final do processo nebuloso é combinar todas as saídas nebulosas em um resultado abrupto específico, o qual será considerado como a saída do sistema, para derivar a saída nebulosa utiliza-se neste caso o operador nebuloso “max” [42] para cada etiqueta consequente, tem-se:

DP com 0,8

ZO com 0,5

DM com 0,4

As funções de pertinência dos conjuntos nebulosos de saída são mostrados na figura 3.11.




Figura 3.11: Funções de pertinência para os conjuntos nebulosos de saída

O método de avaliação das regras utilizado aqui chama-se de inferência min-max. Tomou-se o mínimo dos antecedentes para determinar o peso da regra e o máximo peso das regras para cada consequente para determinar a saída nebulosa. O passo seguinte é encontrar o ponto de equilíbrio do centro de gravidade da área achureada, o qual representa a saída nebulosa denebulizada. Pode-se observar que para dois antecedentes ativam-se quatro regras e tem-se três conjuntos nebulosos de saída, obtendo-se uma área achureada comprida “enfraquecendo” assim o significado da saída nebulosa. É evidente que o número de regras ativadas pode incrementar-se exponencialmente com o número de variáveis de entrada (antecedentes) e consequentemente pode incrementar o número de conjuntos nebulosos de saída, produzindo um incremento no comprimento da área achureada o que se traduz em uma perda de informação do sistema [25].

A tabela 3.10 mostra alguns sistemas especialistas utilizando conjuntos nebulos-

mas ao mesmo tempo aclara-se que a lista não é exaustiva, mas apenas uma referência.

| Nome | Área de aplicação | Representação do conhecimento / Inferência | Referência Bibliográfica |
|----------|-------------------------|--|--------------------------|
| ARIES | Ferramenta | Regras/ Redes | [5] |
| CADIAG-2 | Diagnóstico Médico | Regras | [2] |
| EMERGE | Análise da dor torácica | Regras | [40] |
| FINDEX | Prognosticador | Regras | [90] |
| SPHINX | Diagnóstico Médico | Árbores, regras | [30] |

Tabela 3.10: Sistemas especialistas e ferramentas utilizando a teoria de conjuntos nebulosos

3.4.5 Dificuldades com os Métodos nebulosos

O sistema de lógica nebulosa tem múltiplas escolhas, por exemplo o nebulizador pode ser singletão ou ter formas funcionais para as funções de pertinência (tipo S, tipo Z, tipo II, triangular, trapezoidal), a composição pode ser max-min, max-produto, a inferência pode ser min ou produto e o denebulizador (centróide, denebulizador máximo, meio do máximo, etc.). A escolha entre as possibilidades nos leva a 60 formas diferentes de sistemas de lógica nebulosa. Isto demonstra a riqueza dos sistemas de lógica nebulosa.

Mas, deve-se indicar que o encadeamento de regras nem sempre é uma tarefa simples, isto não é tão complicado quando os sistemas, como no caso de controle, não precisam propagar a imprecisão através de cadeias de regras. Portanto, em sistemas especialistas nebulosos baseados em regras a propagação da imprecisão através de longos encadeamentos de regras deve ser cuidadosamente analisada para evitar chegar a resultados inexpressivos [73] [86].

3.5 Avaliação dos Métodos

Como pode-se ver não há um consenso claro sobre qual é o melhor método para tratar incerteza e/ou imprecisão, embora um número de técnicas foram estudadas tais como a probabilidade Bayesiana, fatores de certeza, Dempster-Shafer, e a lógica nebulosa.

A teoria de Dempster-Shafer parece ter dificuldades em tratar com crenças que estão próximas de zero. Resultados muito diferentes são obtidos quando as crenças são zero se comparadas quando as crenças são muito pequenas [29]. Um outro problema com a teoria Dempster-Shafer é a explosão exponencial no número de computações à medida que aumentam as possíveis respostas a um problema de diagnóstico.

Embora as aproximações de Gordon e Shortliffe [33] evitem a explosão exponencial, poderiam produzir resultados pobres no caso de evidência altamente conflitiva. Foi dada uma abordagem alternativa que não é uma aproximação e dá bons resultados para evidência hierárquica sem a explosão combinatorial [32]. O maior benefício de todos estes trabalhos foi o reexame dos fundamentos da teoria da probabilidade e a ampliação do interesse em métodos para tratar com incerteza.

Até aqui foram apresentadas teorias probabilísticas e não probabilísticas para tratar com a incerteza e/ou imprecisão em sistemas especialistas:

- A interpretação da probabilidade Bayesiana ($P(A | E)$), como o grau de crença de A dada a evidência E , apresenta a probabilidade como um método para tratar incerteza. Mas as considerações de independência das evidências, nem sempre verdadeiro em medicina, tornam difícil a utilização deste método em sistemas especialistas.
- Os fatores de certeza são simples de implementar e foram utilizados com êxito em sistemas especialistas tais como o MYCIN onde as cadeias de inferência são curtas. Contudo, a teoria da certeza é uma teoria *ad hoc* que não se apresenta geralmente como válida para cadeias de inferência longas.
- A teoria de Dempster-Shafer tem um fundamento rigoroso e mantém esperanças em sistemas especialistas. Contudo, na atualidade, parece não existir

um consenso claro sobre como aplicá-lo para uso geral em sistemas especialistas.

- A lógica nebulosa é a teoria mais geral de imprecisão que tem sido formulada. Tem uma ampla aplicabilidade devido ao princípio de extensão. Desde o primeiro artigo de Zadeh [91], a teoria nebulosa tem sido aplicada em muitos campos.

Capítulo 4

Raciocínio Clínico e Tomada de Decisão

Decidir é uma das atividades essenciais da medicina. A elaboração de uma decisão passa teoricamente pelo estabelecimento de estratégias e/ou das ações possíveis, a determinação das consequências de cada decisão, e a escolha, em função do contexto, da solução mais apropriada. Mas esta situação raramente ocorre na medicina. As informações clínicas de início são frequentemente imperfeitas, subjetivas ou não específicas [24]. As hipóteses possíveis são muito numerosas para serem examinadas individualmente. O conhecimento das consequências de cada decisão está frequentemente fragmentada e o efeito previsível dos tratamentos conhecidos encontram-se de maneira aproximada. A decisão médica é uma decisão sob incerteza e imprecisão. Ela é expressa por um juízo que está geralmente unido à “preferência ” por uma conduta julgada ótima. O objetivo do médico é reduzir ao máximo a incerteza pela aquisição de informações complementares, aquisição esta que será guiada pela ativação de conhecimentos múltiplos e complexos.

A informática pode facilitar a tomada de decisão médica e melhorar a qualidade do diagnóstico ou a eficiência da atividade terapêutica. Mas a construção de SE de apoio à decisão exige uma atitude introspectiva necessária à formalização do problema e das soluções consideradas. Esta busca permite a melhor compreensão dos mecanismos de raciocínio clínico e da elaboração dos conhecimentos que assegurem este raciocínio.

4.1 Métodos de Raciocínio

Neste capítulo apresenta-se de maneira esquemática os métodos de raciocínio e analisa-se as características nos métodos usados no raciocínio clínico.

4.1.1 Raciocínio Dedutivo

Permite passar de um caso geral a um caso particular, por exemplo, se a regra “todos os homens são mortais” é verdadeira então Sócrates que é homem, é mortal (*modus ponens*). Os resultados de uma inferência lógica podem servir de premissa para uma dedução ulterior. Assim, se $A \Rightarrow B$ e $B \Rightarrow C$ então, por transitividade $A \Rightarrow C$. O raciocínio dedutivo supõe a existência de regras lógicas e conhecimentos certos que permitam relacioná-los entre eles desde proposições. Dentro dessas lógicas, as proposições só podem ter os valores verdadeiro ou falso. A figura 4.1 mostra vários métodos de raciocínio.




Figura 4.1: Diferentes tipos de raciocínio

4.1.2 Raciocínio Indutivo

Permite passar, através da generalização, de um caso particular a uma lei mais geral. O raciocínio indutivo produz inferências válidas com um certo grau de credibilidade ou de probabilidade. Se os homens x , y , z são mortais, então põe-se como hipótese de indução que todo homem é mortal. Das experiências repetidas permite confirmar ou negar uma hipótese proposta.

Dentro da prática médica o raciocínio por indução está limitado pelo fato que os eventos frequentes são muito mais fáceis de perceber que os eventos raros. Assim, dos diagnósticos e dos sinais, podem-se evidenciar como covariantes neste caso mesmo

que eles não estejam ligados. Estas falsas correlações diminuem a qualidade da utilização dos dados.

4.1.3 Raciocínio Abduativo

É um componente importante da atitude científica. Se dispõe de observações entre as quais esforça-se para estabelecer uma regra, assim como uma relação de causalidade. As hipóteses podem direcionar a escolha de uma lei que permita estabelecer a ligação entre os fatos considerados como antecedentes e consequentes (por exemplo hipótese de diagnóstico) ou sob o estabelecimento de uma nova lei (por exemplo descoberta científica), ver figura 4.1.

4.1.4 Raciocínio Causal

Frequentemente os sinais aparecem posteriores a uma cronologia particular (no caso das doenças infecciosas ou parasitárias). A causa responsável passa pela análise detalhada destas cronologias e das relações entre a causa e as consequências supostas da causa. Assim, por exemplo, para poder atribuir um efeito secundário a um medicamento, deve-se verificar:

1. Que o medicamento foi administrado antes da aparição dos efeitos secundários,
2. Que o retardo na aparição é compatível com o conhecimento dos efeitos do medicamento,
3. Que a eliminação da causa leva a eliminação do efeito (reversível),
4. Que o reinício da causa, se ela é eticamente possível, acontece a reaparição do efeito,
5. Que a intensidade do efeito é proporcional à quantidade de medicamento administrada.

4.2 As etapas da decisão médica

De maneira esquemática, três etapas podem ser distinguidas na decisão médica, como mostra-se na figura 4.2.

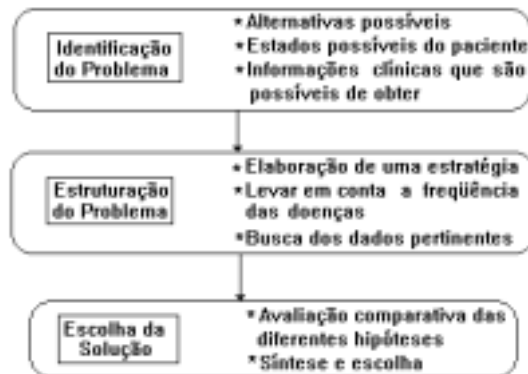


Figura 4.2: Etapas do processo de decisão

4.2.1 Identificação do problema

Esta é a primeira etapa e refere-se à identificação do problema, que determina o domínio do conhecimento relacionado com ele. Para a decisão do diagnóstico, o médico inicia desde a interpretação primária dos dados clínicos. O médico deve escolher as informações relevantes a partir de numerosos dados de partida (abstração). A identificação da informação pertinente está diretamente condicionada pela experiência de quem decide. Ela acontece a partir de agora associada ao raciocínio abdutivo.

4.2.2 Estruturação do problema

Nesta etapa é a estruturação do problema e da informação clínica. Numerosas interpretações podem ser feitas a partir das mesmas informações ou de uma parte dessas mesmas. A formação das hipóteses de diagnóstico encontram sua fonte dentro da estruturação das informações. O raciocínio pode ser de natureza dedutiva (caso de um sinal patogênico), indutiva (diagnóstico de uma doença transmissível dentro de uma população de risco) ou abdutiva.

4.2.3 Escolha da solução

Esta viria a ser a etapa final, onde a resolução do problema implica a sua transformação. Do problema mal definido na origem (qual doença tem o paciente?), o médico deve passar a um problema bem definido: O paciente tem a doença *X*?. A partir das hipóteses levantadas, os sinais vistos podem ser obtidos por dedução e

eventualmente pela aquisição dos exames complementares necessários. Os resultados dos exames complementares permitem então reduzir a incerteza sobre a situação clínica, eliminação de hipóteses e/ou levantamento de novas hipóteses.

Este processo se refere ao conhecimento aprendido, memorizado e estruturado. Assim, a medicina buscará novas interpretações diagnósticas no momento que uma hipótese não seja satisfeita, isto é, em contradição com o conhecimento memorizado e utilizado. Esta etapa do processo do diagnóstico está caracterizado pelas operações cognitivas de avaliação desde interpretações realizadas e supondo um envolvimento ativo do médico para controlar a quantidade das informações úteis. Ele deverá levar em conta o custo das diferentes estratégias possíveis.

4.3 Decisão clínica

Diante da mesma situação, dez médicos podem estar motivados a utilizar estratégias de decisão diferentes. Isto é particularmente verdadeiro ao considerar a utilização de exames especiais invasivos. De fato, as decisões elaboradas pelos médicos podem estar esquematizados pelo modelo geral da “lente de Brunswick” (figura 4.3).




Figura 4.3: Modelo da lente de Brunswick

O clínico baseia-se sobre os critérios (A, B, C...) e as relações existentes, de uma parte, entre a situação apresentada e os critérios e de outra parte, entre o juízo pessoal e os critérios. Brunswick, citado em [24], ressalta que a decisão situa-se dentro de um meio probabilístico e não exato. O significado dado à informação obtida está ponderado, pelo meio e a memória do clínico, estas ponderações são combinadas para formar o decisão final. Assim, o processo de decisão permite:

1. Combinar as fontes de informação que não são estatisticamente independentes,

em particular as informações clínicas redundantes,

2. Levar em consideração a confiabilidade das fontes de informação,
3. Levar em conta o valor preditivo das diferentes fontes de informação,

4.4 Incerteza e imprecisão na decisão clínica

A decisão clínica pode estar cheia de desvios cognitivos que se manifestam ao longo do processo de decisão. A seguir apresentam-se algumas delas:

1. A partir da aquisição dos dados, a ordem dentro do qual as informações são “densas”, é uma fonte de erro. As primeiras informações “densas” podem dominar as posteriores.
2. A coleta das informações está baseada sobre as “expectativas”, resultado do contexto extrapolado da pessoa que toma a decisão.
3. O julgamento humano nem sempre toma suficiente conta da confiabilidade dos dados (as fontes de dados são consideradas como perfeitamente confiáveis).
4. O conservadorismo, termo utilizado pelos anglo-saxões, traduz a dificuldade em revisar uma opinião. Este fenômeno está caracterizado pela tendência a favorecer uma certa interpretação e a racionalizar ou ignorar as evidências contrárias.
5. A inconsistência do julgamento se traduz na contradição que existe na formação de opiniões diferentes sobre casos idênticos.
6. A justificabilidade conduz a aplicar uma regra, se achasse uma razão para justificá-la, mesmo se ela não é apropriada.

Os pontos acima expostos ilustram a dificuldade na compreensão do processo de decisão clínica.

Modelar o processo de decisão clínica é portanto uma tarefa complexa, que deve levar em conta características tais como a incerteza das hipóteses de diagnóstico a partir da imprecisão das informações (sintomas, testes laboratoriais, etc.). Pode-se utilizar a lógica nebulosa para tratar a imprecisão nos dados clínicos, mas tem-se visto que os sistemas nebulosos baseados em regras apresentam dificuldades na

propagação da imprecisão em longas cadeias de regras. Uma maneira de resolver este inconveniente, é modelar o raciocínio do clínico especialista como um raciocínio por analogia, que tem sua fundamentação teórica no estudo do raciocínio plausível desenvolvido por George Polya [66] e apresentado no Capítulo 2, evitando assim a propagação da imprecisão que ocorre em sistemas baseados em regras. De modo que, não se terá dificuldade ao utilizar métodos nebulosos, apresentados no Capítulo 3, para tratar a imprecisão dos dados clínicos. Estas idéias serão desenvolvidas sob a plataforma do Raciocínio Baseado em Casos que na área da inteligência artificial, foi inicialmente desenvolvida por Roger Schank [75].

Capítulo 5

Área de Aplicação : Reumatologia

Milhões de indivíduos em todo o mundo são acometidos por dores articulares. Em conseqüência disto, qualquer clínico geral pode esperar ver numerosos pacientes reclamando de “reumatismo” ou “artrite”.

O diagnóstico de doença reumática encontra diversas dificuldades, sendo que o problema fundamental é o de diferenciar as artrites inflamatórias das patologias articulares não-inflamatórias.

Diferenciar afecções reumáticas aparentemente pode, sob o ponto de vista clínico, determinar um problema que coloca em prova a capacidade, o saber e a experiência do médico, mesmo o mais metuculoso.

Entretanto, o diagnóstico reumatológico pode ser determinado em numerosos casos pelo clínico geral que segue o esquema aceito de um exame clínico clássico, constituído por uma anamnese completa, realização de um exame físico minucioso e, se possível, recorrer a exames complementares apropriados.

5.1 Conceito

A conceituação das doenças reumáticas apresenta uma série de obstáculos nem sempre fáceis de contornar. A interpretação do vocábulo “reumatismo” de origem grega em seu sentido puramente etimológico, de fluxo, fluir, correr; não favorece a compreensão da maneira atual e ampla em que é empregado o termo do reumatismo. Para De Séze [26], os reumatismos compreendem um grupo de moléstias que apresentam um duplo caráter: o de atingir de preferência os elementos derivados do mesoderma e o de depender de causa que escapa ainda ao nosso conhecimento. Hollander [39] infere que doenças reumáticas são as condições nas quais se tornam

proeminentes, em algum segmento do sistema músculo-esquelético, a dor e a impotência funcional, incluindo-se as afecções do tecido conjuntivo. Dixon [27], por outro lado, acha possível definir a reumatologia como sendo o estudo da artrite reumatóide e das doenças que com ela se parecem. Supomos diante dos ilimitados horizontes que se têm aberto e da conseqüente expansão da área englobada pela reumatologia, que se possa aceitar como o estudo de todas as afecções do sistema osteoarticular. Fixar os limites exatos de uma especialidade é praticamente impossível. Basta considerar o fato óbvio e básico da unidade funcional orgânica. Mesmo as especialidades mais antigas e definidas não se puderam separar completamente das demais. Muitas delas fragmentaram-se, surgindo novas, e continuarão a fragmentar-se. Os próprios critérios que dão e deram lugar à formação de especialidades são variados, ora organicistas, ora topográficos, ora etários, ora nosológicos, ora patogênicos.

A reumatologia faz fronteira com quase todas as especialidades, pois as principais e mais graves formas de patologias reumáticas e doenças afins têm caráter geral, acometendo, freqüentemente, vários órgãos e sistemas, não sendo simples afecções articulares e musculares.

5.2 Classificação

Alguns fatos podem ser hoje bem abordados. Seguramente, pode-se afirmar que estas entidades não constituem grupo uniforme, pois para a uniformidade não existe base anatomo-patológica, etiológica e patogênica [83].

O tecido conectivo apresenta uma monotonia reacional, traduzindo-se por um mesmo tipo de alteração histopatológica, comum a doenças de características etio-patogênicas completamente diferentes.

As afecções difusas do tecido conectivo são doenças primárias deste tecido, sem caráter tumoral ou infeccioso, essencialmente difusas, atual ou potencialmente. Partindo desta conceituação, poderíamos colocar dentro deste agrupamento de afecções difusas do tecido conectivo a doença reumática, doença reumatóide, a esclerose sistêmica progressiva, o lúpus eritematoso sistêmico, a polimiosite e o síndrome de Sjögren [23].

Deve-se aclarar que há inexistência de uma classificação ideal e ainda até hoje continua-se modificando.

Ao classificar, determina-se as categorias em que se divide e subdivide um con-

junto. Isto presume um critério definido, uniforme, único. Para se chegar a esse critério é indispensável o conhecimento completo e exato do que se vai ordenar. Tal não ocorre em relação aos reumatismos. Por isto não se tem uma classificação definitiva.

Não se pode agrupar os reumatismos segundo sua etiologia ou patogenia, norma que seria provavelmente a mais correta, porque delas tem-se informações incompletas, parciais e duvidosas. Discriminá-los topograficamente, em articulares e não articulares, é fugir à realidade clínica que pode identificar num mesmo quadro, freqüentemente, a associação dessas formas nos comprometimentos globais de uma só patologia. O critério evolutivo, agudos e crônicos, não tem sentido: na verdade todos os reumatismos são crônicos, com fases de latência e surtos de exacerbação. E assim sob todos os ângulos por que se examine atualmente o problema, as críticas poderão ser contundentes [77].

A *American Rheumatism Association* lançou em 1964 uma alternativa de classificação, que foi revista em 1973. Nela, as doenças são classificadas em 12 subgrupos [77]:

1. Poliartrites de etiologia desconhecida
2. Afecções do tecido conjuntivo (adquiridas)
3. Febre reumática
4. Doença articular degenerativa (osteoartrite, osteoartrose)
5. Reumatismo não articular
6. Doenças com as quais a artrite está freqüentemente associada.
7. Associada a agentes infecciosos conhecidos
8. Afecções traumáticas e/ou neurogênicas
9. Associadas a anormalidades bioquímicas ou endócrinas conhecidas ou fortemente suspeitas
10. Neoplasmas
11. Reações alérgicas e medicamentosas.
12. Doenças hereditárias e congênitas.

Dentro das quais encontra-se a Artrite Reumatóide no primeiro subgrupo e o Lúpus Eritematoso Sistêmico no segundo subgrupo.

A reação imune contra os antígenos “próprios”, autoimunidade, é bem reconhecida hoje como causa de doença. Existe, entretanto, muita controvérsia quanto aos critérios para o diagnóstico de doenças de origem autoimune [83]. A designação de uma condição como doença imune é, pois, algo arbitrária e baseia-se em:

1. Evidência de uma reação autoimune.
2. O julgamento de que os achados imunológicos não são meramente secundários.
3. A falta de qualquer outra causa identificada para a doença.

Mas, a despeito de muitas incertezas, uma série de condições foram adequadamente designadas como doenças autoimunes, dividem-se em dois subgrupos os quais se subdividem em outros dois:

1. Tipo celular ou órgão único

- provável
- possível

2. Sistêmicas

- provável
- possível

Onde, encontramos a Artrite Reumatóide e Lúpus Eritematoso Sistêmico na primeira subdivisão do segundo subgrupo.

5.3 Manifestações clínicas

As afeções se caracterizam por seu caracter difuso. Desta forma, as manifestações clínicas são as mais variadas, dependendo dos órgãos ou aparelhos atingidos. É bem compreensível o achado de sintomas e sinais comuns as entidades mórbidas deste agrupamento, podendo-se entretanto, em determinadas doenças, encontrar não só frequência diversa de manifestações, como também de suas características, sugerindo a distinção entre elas [23]tem-se:

- As articulações são mais persistente e intensamente atingidas na doença reumatóide, embora o possam ser também no lupus eritematoso sistêmico, e sendo discreta e transitória na doença reumática, polimiosite e doença do soro.
- Os músculos são agredidos de modo acentuado nas polimiosites, sendo este comprometimento menos importante na doença reumática, no esclerodema e no lupus eritematoso sistêmico.
- O rim é atingido, indicando maior gravidade da afeção, principalmente no lupus eritematoso sistêmico e menos freqüentemente no esclerodema, síndrome de Sjögren e doença reumatóide.
- O coração é comprometido em todas as entidades que cogitamos, sendo mais comum na doença reumática, lupus eritematoso sistêmico e doença reumatóide. Menos freqüentemente nas demais enfermidades.
- A pele está afetada notadamente no esclerodema generalizado e, de modo também importante, no lupus eritematoso sistêmico, dermatomiosite, doença reumatóide, doença reumática e síndrome de Sjögren.
- O subcutâneo mostra principalmente os nódulos sugestivos da doença reumatóide, doença reumática, etc.
- As serosas são muito comprometidas, particularmente no lupus eritematoso sistêmico, embora possa ocorrer em outras condições menos freqüentemente.
- Os pulmões são atingidos com relativa freqüência em intensidade, em muitas destas afeções, como a doença reumatóide, a esclerose sistêmica progressiva, o lupus eritematoso sistêmico, a doença reumática e outras.
- O aparelho digestivo é particularmente agredido na esclerose sistêmica progressiva, menos freqüentemente no lupus eritematoso sistêmico, na doença reumatóide e outras.
- Quadros neurológicos e psiquiátricos são descritos com incidência cada vez maior, destacando-se o lupus eritematoso sistêmico, a doença reumática, a doença reumatóide, o síndrome de Sjögren.

Será estudado separadamente somente as enfermidades para as quais será desenvolvido o SE, para o melhor conhecimento dos seus aspectos clínicos.

5.4 Lupus Eritematoso Sistêmico (LES)

Trata-se de uma doença febril, inflamatória, generalizada (multissistêmica) e de manifestações e comportamento variáveis. Caracteriza-se pelos seguintes aspectos [53]:

1. Clinicamente, é uma doença de recidivância imprevisível, de início agudo ou insidioso que pode comprometer praticamente qualquer órgão do organismo, porém afetando principalmente a pele, rins, membranas serosas, articulações e coração;
2. Anatomicamente, todos os sítios de comprometimento apresentam em comum lesões vasculares com depósitos fibrinóides;
3. Imunologicamente, a doença compreende um enorme conjunto de anticorpos de presumível origem autoimune. Desta forma, uma série de anticorpos tem sido demonstrada nesta entidade mórbida e entre eles esta o fator L.E.

Os elementos clínicos, como é fácil prever, são muito variáveis e podem imitar um grande número de outras entidades clínicas. Os mais comuns são:

1. febre
2. artralgia
3. artrite
4. mal estar geral
5. lesões cutâneas
6. emagrecimento
7. adenopatia
8. hepatomegalia
9. esplenomegalia
10. lesões gastrintestinais
11. lesões renais

12. lesões cardíacas
13. lesões pulmonares
14. manifestações psiquiátricas e neurológicas.

5.4.1 Critérios Diagnósticos

A apresentação clínica do LES é tão variável e com tantas semelhanças com outras doenças autoimunes do tecido conectivo (artrite reumatóide, polimiosite, dermatomiosite e outras) que tornou-se necessário o estabelecimento de critérios diagnósticos. Onze aspectos da doença foram selecionados, permitindo o diagnóstico de LES se estiverem presentes 4 ou mais durante qualquer período de evolução da doença [53]:

1. eritema facial
2. eritema discóide
3. fotossensibilidade
4. úlcera oral
5. artrite
6. serosite
7. distúrbios renais
8. distúrbios neurológicos
9. distúrbios hematológicos
10. distúrbios imunológicos
11. anticorpos antinucleares

5.4.2 Patologia

Uma enorme quantidade de dados aponta para uma patogenia autoimune para o LES, porém a causa ou causas desta enfermidade de reações autoimunes ainda é desconhecida.

O LES parece ser uma doença multifatorial, envolvendo complexas interações entre fatores genéticos, virais, hormonais e ambientais, todos possivelmente atuando em conjunto para produzirem distúrbios imunológicos [83].

As alterações morfológicas no LES são grandemente o resultado da formação de imune complexos e sua deposição em uma série de tecidos. O LES é, portanto, uma doença sistêmica com manifestações proteiformes.

5.4.3 Manifestações Clínicas

- O diagnóstico do LES poderá ser óbvio num paciente com a clássica erupção facial em asa de borboleta, febre, dor sem deformidades em uma ou mais articulações periféricas (pés, tornozelos, joelhos, quadril, dedos, punhos, cotovelos, ombros), dor torácica pleurítica e fotossensibilidade. Entretanto em vários pacientes a apresentação do LES é sutil e enigmática, assumindo formas variáveis como doença febril de origem desconhecida, achados urinários anormais ou processo articular se assemelhando à artrite reumatóide ou febre reumática [83].
- O curso clínico da doença é o mais variável e praticamente imprevisível, pois os casos tanto podem ter evolução rapidamente fatal, dentro de 6 meses, até evoluções lentamente progressivas.
- A idade de início da doença nem sempre é possível de determinar com segurança. Surge geralmente na segunda e terceira década de vida, podendo manifestar-se em qualquer idade, mesmo na infância.
- Quanto ao sexo, tanto em adultos como em crianças a preponderância é do sexo feminino, cerca de 8 para 1.

A relação com fenômenos alérgicos tem sido lembrada embora não acharem incidência diferente do que na população geral. Há uma importância genética em um estudo a respeito incidência familiar. Estudos epidemiológicos mostraram índices maiores de morbidade e mortalidade da afeção na raça negra [23].

5.5 Artrite Reumatóide (AR)

É uma doença sistêmica, inflamatória, crônica, que compromete principalmente as articulações, podendo também afetar vários aparelhos, além do articular, e re-

missões que podem ser espontâneas e extremamente longas, embora geralmente com a presença de sintomas menores, reaparecendo as manifestações mais intensas pela ação de diversos fatores precipitantes, entre eles os emocionais [23]. Mais especificamente, a doença caracteriza-se por uma sinovite proliferativa poliarticular não supurativa, a qual leva, com a evolução, a uma destruição da cartilagem articular e uma artrite invalidante progressiva. Embora a AR seja basicamente uma artrite poliarticular simétrica, o comprometimento articular é frequentemente precedido por sintomas constitucionais tais como fraqueza, mal estar e febre moderada. Dentre os sintomas e sinais comuns tem-se [52]:

1. rigidez nas articulações.
2. dor nas articulações.
3. fraqueza.
4. fadiga.
5. depressão psicológica.
6. edema.
7. eritema palmar.
8. sudoração fria.
9. atrofia muscular.
10. intumescimento de articulações.
11. nódulos.
12. hérnia sinovial.
13. perda de peso.

5.5.1 Critérios Diagnósticos

O comprometimento multisistêmico da AR deve ser diferenciada do LE, esclerodema, polimiosite-dermatomiosite e febre reumática, bem como outras formas de artrite. Foram estabelecidos critérios diagnósticos pela *American Rheumatism Association* [83]:

1. Rigidez matutina.
2. Dor articular ou dor à movimentação.
3. Edema de partes moles de uma articulação.
4. Edema de partes moles de uma segunda articulação (dentro de 3 meses).
5. Edema de partes moles de articulações simétricas (excluindo articulações interfalangeanas distais).
6. Nódulos subcutâneos.
7. Alterações radiológicas.
8. Positividade sérica de fatores reumatóides.

Onde três ou quatro pontos indicam AR “provável” e cinco ou mais pontos AR “definitiva”.

5.5.2 Patologia

A AR é causada por uma inflamação persistente e autoperpetuadora resultante de um processo imunológico que atinge as articulações. Ainda que a lesão articular na AR seja de origem imunológica e pareça ocorrer em indivíduos geneticamente predispostos, continua desconhecido o fator que desencadeia a aparente reação imune [83].

A AR é uma doença sistêmica que pode causar lesão significativa em muitos órgãos. Seu lado mais destrutivo repercute nas articulações. Basicamente, produz uma artrite simétrica que afeta principalmente as pequenas articulações das mãos e pés, tornozelos, joelhos, punhos cotovelos, ombros, articulação têmporo-mandibular e, às vezes, as articulações da coluna vertebral.

5.5.3 Manifestações Clínicas

- O diagnóstico: a artrite surge, em geral, insidiosamente, sendo o sintoma de real significado a rigidez articular ou desconforto, especialmente pela manhã. A manifestação mais comum é a articular, a artropatia e geralmente inflamatória, em boa parte dos casos simétrica e centrípeta, embora as pequenas

articulações das mãos (particularmente articulações interfalangeanas e metacarpofalangeanas) sejam inicialmente afetadas, outras articulações tornam-se envolvidas, agredindo a membrana sinovial, cápsula e tendões. Os nódulos podem estar presentes nos casos mais intensos, muito frequentemente associados à doença de curso sem remissões, porém não relacionados à duração da doença. Têm-se também manifestações respiratórias (pleurite e pneumonite), renais, neurológicas (neuropatia periférica, e outras), gastrintestinais, musculares (com verdadeira miopatia) e oculares que caracterizam o aspecto generalizado da doença [83].

- A doença reumatóide nos jovens apresenta comprometimento mais intenso no setor visceral, destacando-se os eritemas, esplenomegalia, linfadenopatia, pericardite, pleurite, perturbações do crescimento, hipertermia, ceratite e iridociclite, nódulos. À medida que a doença progride, as articulações aumentam de volume; a movimentação é limitada. Os dedos tornam-se virtualmente imobilizados, em forma de garra, com desvio ulnar. Neste estágio da doença é comum a anemia. A vasculite pode dar lugar ao fenômeno de Raynaud, úlceras crônicas das pernas e erosões da mucosa gastrointestinal e, de fato, pode causar enfartes no cérebro, coração e intestino. É óbvio que com este comprometimento multisistêmico, a AR deve ser diferenciada do LES, escleroderma, polimiosite-dermatomiosite e febre reumática, bem como outras formas de artrite [23].
- No diagnóstico diferencial são essenciais os seguintes pontos [83]:
 1. achados radiológicos característicos,
 2. fator reumatóide. Deve-se ter em mente, porém, que o fator reumatóide pode estar presente no LES, sarcoidose, lepra, sífilis e outros processos do tecido conectivo.
- A idade, acomete principalmente adultos jovens, podendo iniciar-se a qualquer idade, ainda que a freqüência da afeção aumenta nitidamente com a idade a partir dos 25 anos [23].
- No sexo, a incidência é maior nas mulheres, sendo 2 a 3 vezes mais comum do que em homens. O aumento maior ocorre na quarta e quinta décadas na mulher e acima dos 65 anos no homem [83].

Capítulo 6

S. E. Nebuloso para Diagnóstico Médico

A inferência clínica é um processo no qual o médico utiliza seu conhecimento para inferir um diagnóstico desde os sintomas apresentados pelo paciente, resultados de testes laboratoriais aos quais submeteu-se o paciente, a observação dos sinais clínicos por parte do médico e a história clínica do paciente. Este raciocínio é complexo e em parte um processo não pesquisado na qual o médico é capaz de trabalhar incerteza e conjuntos de dados imprecisos[2].

Enquanto a Psicologia Cognitiva estuda os mecanismos subjacentes no comportamento humano, a Psicologia Behaviorista concebe a atividade mental como as ações observáveis (conduta e comportamento) partindo do paradigma:

ESTÍMULO → RESPOSTA

A atividade mental faz referência às ações inobserváveis. Assim, a preocupação da Psicologia Cognitiva é abrir a “**Caixa Preta**” para pesquisar o que existe entre um estímulo e uma resposta.

Há interesse nos modelos de processamento e de tratamento da informação que um médico produz dentro de sua memória, e quais são os métodos ou procedimentos que ele utiliza para dar solução a uma situação determinada.

Não basta obter dados. Precisa-se discriminar, reconhecer e identificar operações mentais que dependem de experiências passadas (casos ou histórias). Precisa-se registrar temporariamente ou permanentemente a informação na mente, compreender seu significado, transformá-la de modo a ajustá-la às estruturas cognitivas preexistentes. Realiza-se mentalmente operações lógicas, estabelece-se relações, faz-se in-

ferências, analisa-se e reestrutura-se as representações mentais, formula-se hipóteses e planos de ação, toma-se decisões, vale-se de diferentes procedimentos para resolver problemas.

Nestas atividades cognitivas considera-se que existem três classes de atividades mentais: compreensão, raciocínio e avaliação.

1. A Compreensão:

Consiste em construir interpretações. O produto desta atividade é uma representação de uma situação de trabalho e, a partir daí, tratamentos posteriores podem ser realizados como: a abstração e organização dos conhecimentos, a elaboração de hipóteses de ação e de tomada de decisão, etc.

2. O Raciocínio

É produzido pelas inferências. As informações, necessárias para produzir o raciocínio são: as informações contidas na representação de uma situação e, os conhecimentos armazenados na memória.

Os raciocínios produzem inferências: pelas regras que definem as condições de passagens de informação para outra e, na utilização dos conhecimentos compactados e armazenados na memória. Isto é, os cenários ou modelos de raciocínio.

O raciocínio por analogia utiliza os conhecimentos que são generalizados. Estes são representados em cenários ou marcos específicos que tratam situações particulares.

A analogia trabalha, na solução de problemas, quando uma determinada situação não apresenta as condições exatas para a aplicação de um determinado cenário ou domínio de conhecimento, mas as condições apresentadas são semelhantes a uma situação acontecida. Isto é, em ausência de um conhecimento apropriado para um determinado problema, a analogia utiliza o conhecimento de situações passadas, de forma a propor uma solução ao problema ou realizar as correções necessárias[38].

3. As atividades de avaliação.

Os produtos das atividades de avaliação são os julgamentos que determinam como se situa um objeto ou uma situação sobre uma norma.

As informações utilizadas pelas atividades de avaliação são as informações dos

objetos ou das situações e, de outra parte, as normas ou os critérios considerados na avaliação.

A memória dos especialistas não está organizada como um sistema de regras. Ela é uma biblioteca de experiências. Além disso, estas bibliotecas são adaptáveis a certas situações. Por exemplo, quando uma nova experiência aparece, esta não pode simplesmente ser adicionada na memória como uma experiência simples. Uma experiência nova pode modificar, substituir, ampliar ou produzir perturbações nas experiências alocadas na memória. Aprender com a experiência significa mudar o que se conhece, para alocar um novo conhecimento dentro de sua memória. Regras são como a experiência depois de compilada para uma linguagem de regras.

Um fenômeno que espalha muita luz na comunidade de pesquisadores é o problema da recuperação de fatos e nossa habilidade para aprender, a partir do fenômeno da lembrança [75]. A lembrança é um aspecto crucial na pesquisa do funcionamento da memória humana e, realmente, esta tem recebido pouca atenção neste domínio. As pessoas lembram de uma pessoa para outra, de uma construção para outra e assim por diante.

Diferentes modelos de estruturas de conhecimento foram desenvolvidas e cada uma delas resultou de grande importância nos diferentes domínios de estudo [37]:

- os **roteiros** (*scripts*) de Schank e Abelson [74], para a compreensão de textos;
- os **molduras** (*frames*) de Minsky [56], para o reconhecimento de formas;
- os **MOPs** (*Memory Organization Packages*) de Schank [75], aplicado a bases de conhecimento que mudam dinamicamente e,
- os **TOPs** (*Thematic Organization Points*) de Schank [75], aplicado, também, a bases de conhecimento que mudam dinamicamente.

Estas estruturas compartilham numerosos aspectos em comum. Mas, atualmente, os esquemas são o pilar da estrutura do conhecimento.

Para Piaget [65], o desenvolvimento e o começo da inteligência partem do processo de **assimilação/acomodação** de fatos na memória. Isto é, uma ação real necessitaria de uma assimilação de um esquema existente e sua apreensão seria dirigida por um sistema de espera. Assim, toda aquisição de conhecimento se traduziria na acomodação de uma informação a um esquema anteriormente construído, dando lugar a uma nova situação.

Em geral, os esquemas podem ser definidos como uma estrutura de dados que permitem representar os conceitos armazenados na memória. Em outras palavras, eles têm um conjunto de estruturas de informação generalizadas que descrevem como e onde um conjunto de ações tomam lugar. Também, eles têm uma configuração organizada de sabedoria, derivada da experiência e que servem para interpretar novas realidades. Especificamente, eles têm duas características importantes:

1. A informação das atividades que acontecem e,
2. A informação física sobre o cenário.

6.1 Raciocínio por analogia

Um dos objetivos da IA é proporcionar ferramentas formalizadas para registrar os conhecimentos e as heurísticas dos sistemas cognitivos. Isto é, sistemas computacionais que representem o modelo de funcionamento e que manifestem o comportamento do sistema cognitivo dos seres humanos na realização de uma determinada atividade. Por outro lado, a simulação deste sistema permitirá reproduzir o comportamento observado.

Muitos pesquisadores têm tentado construir o modelo de comportamento humano segundo a perspectiva comportamental, por exemplo, decompondo todos os comportamentos de médico em uma seqüência de fatos elementares ou subtarefas e logo alocar a cada um destes, uma certa probabilidade de erro.

Pode-se dizer que só uma mínima parte do raciocínio humano é feita de forma algorítmica. Os médicos, geralmente, não dispõem de tempo para resolver seus problemas com regras.

Mas, normalmente a solução de um problema depende da relativa significância dos fatores do contexto e, muitas vezes, os métodos estatísticos e analíticos não são os mais efetivos. Por exemplo, especialistas acreditam que uma certa característica pode ser mais importante que outra e, raramente, eles podem dar pesos numéricos ou probabilidades para expressar suas diferenças. Entretanto eles estão sempre cientes da possibilidade que em algumas combinações de características, o oposto pode ser verdadeiro e a menor característica pode ser a mais significativa[3].

Segundo a perspectiva da modelagem cognitiva, é mais exato pensar que muitas pessoas com experiência (“**especialistas**”), a diferença dos novatos, resolvem seus problemas do dia a dia, envolvendo situações passadas similares[1]. Assim, lembrar

de experiências ajudam às pessoas na solução de seus problemas, antecipando e evitando erros, e derivando métodos de raciocínio curtos.

Existem muitas evidências de que os especialistas confiam excessivamente em sua memória de casos passados, quando resolvem problemas em domínios, tais como leis, em matemáticas, na física, na medicina[46], e este processo de raciocínio é importante porque faz previsões no entendimento e na aprendizagem. Este fato realmente é o foco de um sistema usando **Raciocínio Baseado em Casos (RBC)** e, constituindo o quinto maior paradigma da pesquisa em aprendizagem de máquinas. É a abordagem do raciocínio por analogia[44].

O processo de um sistema RBC consiste em usar os resultados de episódios passados (casos) para analisar e resolver um problema novo. O sistema pode adaptar soluções passadas aos novos problemas, usando suas experiências para explicar novas situações, para criticar novas soluções, para interpretar novas situações, ou ainda, para criar uma justa solução a um problema apresentado[47].

Esta abordagem é útil quando o conhecimento é incompleto ou as evidências são inexatas. Os sistemas baseados na lógica clássica têm problemas tratando com ambos, porque eles procuram suas respostas em fatos conhecidos e corretos. Alguns sistemas de IA usam fatores e métodos de raciocínio incertos para resolver estes problemas, que exigem considerável esforço, e nada é visto de razoável[46]. Os sistemas RBC fornecem um método, para tratar o conhecimento incompleto. Isto é, o sistema RBC faz hipóteses para preencher o conhecimento incompleto, ou errado, baseado na sua experiência. As soluções geradas desta forma podem ser ótimas.

Os sistemas RBC utilizam o método de raciocínio baseado por analogia. Segundo pesquisas recentes, este é um meio de raciocínio que utiliza casos passados ou experiências em um esforço para resolver problemas [1], explicando situações anômalas ou interpretando situações. Na tabela 6.1 enumeram-se alguns programas que utilizam o raciocínio baseado em casos para resolver problemas ou resolver situações.

Classificar situações é uma forma de entender. Em raciocínios médicos, isto significa determinar uma categoria de patologia na qual um paciente se encontra. Em geral, classificar situações significa encontrar na memória de conhecimento os esquemas mais aplicáveis, ao que está sendo compreendido. Esquemas escolhidos durante o processo de entendimento provêm previsões para utilizá-los neste processo [75]. Escolher uma categoria de diagnóstico, por exemplo, mostra um tratamento apropriado a ser seguido em medicina. Na solução de um problema, esquemas apro-

| Nome | Área de aplicação | Referência Bibliográfica |
|--------------|--|--------------------------|
| MEDIATOR | Mediar disputas | [82] |
| JULIA | Projetista | [43] |
| CHEF | Planejamento | [34] |
| HYPO | Constrói argumentos baseado em leis | [4] |
| PROTOS | Diagnóstico | [8] |
| CELIA | Diagnóstico | [71] |
| SE | Diagnóstico Médico | [6] |
| CONEXIONISTA | | |

Tabela 6.1: Sistemas especialistas desenvolvidos com RBC

priados (esquemas generalizados, por exemplo) fazem predições acerca de possíveis estratégias de resolução de problemas.

Para resolver um problema é necessário entendê-lo. Em um sistema computado-rizado os detalhes não apresentados de um problema, devem ser preenchidos através de um processo de inferência ou de um conjunto de perguntas formuladas por este. Assim, desde que uma classificação é escolhida, as características não encontradas para o caso corrente são utilizadas para atravessar a estrutura episódica da memória. Desta forma, esquemas específicos e casos particulares são encontrados. A analogia de um caso passado tem duas funções na classificação ou no processo de entendimento:

- sugerindo características adicionais a serem investigadas;
- sugerindo uma alternativa ou uma classificação adicional.

Neste tipo de raciocínio, os casos “precedentes”, são usados para encontrar uma nova solução (em uma análise de interpretação, os resultados podem ser a favor ou contra, e é possível apresentar um resumo da sensibilidade de alguns de seus fatores) e justificar e explicar a racionalidade do processo.

Em geral, este estilo de raciocínio é útil para uma situação de classificação; avaliação de uma solução; argumentação; justificação de uma solução, interpretação de um plano de ação; e a projeção dos efeitos da tomada de decisão.

6.2 Raciocínio Baseado em Casos e Raciocínio Baseado em Regras

O raciocínio baseado em casos é útil quando as pessoas conhecem uma porção de uma tarefa ou de um domínio e, porque proporciona a eles uma maneira de voltar a usar um forte raciocínio que eles fizeram no passado. Por outro lado, considerando um sistema baseado em regras que resolve problemas, tomando uma informação de entrada (ou através de um diálogo, de perguntas e respostas, com o usuário), o sistema posteriormente encadeará um conjunto de regras da base de regras, para chegar a uma determinada solução (ver Figura 6.1).




Figura 6.1: Como um sistema especialista baseado em regras resolve problemas

Assim, dada a mesma situação do problema, o sistema faz a mesma quantidade de trabalho para chegar à mesma solução. Em outras palavras, o aprendizado não é inerente aos sistemas baseados em regras. Estes sistemas consomem muito tempo para serem construídos e para realizar sua manutenção. A extração dos conhecimentos do especialista é um trabalho constante e esta é dependente de um conjunto de regras.

Por outro lado, os sistemas RBC operam de uma forma muito diferente dos sistemas convencionais (ver Figura 6.2).




Figura 6.2: Como um sistema especialista baseado em casos resolve problemas

Por exemplo, dada uma determinada especificação, um sistema baseado em casos pesquisa na sua memória a existência de um caso semelhante às características do

problema. Assim, o sistema vai procurar (a variabilidade dos objetos decrescem quando são adicionados casos novos ao sistema) o melhor caso, ou um conjunto de casos, para poder dar uma solução ou recomendação ao problema.

Os sistemas baseados em casos devem encontrar e modificar pequenas porções de casos recuperados que não se encaixam nas especificações de entrada. Isto é chamado de adaptação de um caso. O resultado da adaptação de um caso é a completa solução do problema. Assim, este processo gera um caso novo que pode ser automaticamente adicionado à memória do sistema para seu posterior uso (a **aprendizagem** é uma parte básica da arquitetura do sistema RBC).

A idéia de utilizar RBC tomando decisões, consiste em elaborar sistemas computadorizados que ampliem a memória das pessoas, provendo com casos ou histórias (análogas) para que estas possam ser utilizadas na solução de um problema.

Aprender com experiências é uma forma de assimilar conceitos. Muitas pessoas que tomam decisões, frente a novos problemas, se beneficiam da experiência ao resolver um problema, com soluções adequadas de casos ou de problemas passados.

A idéia do RBC depende da habilidade do sistema para comunicar e explorar a similaridade entre uma situação nova e algum caso ou história previamente representado na memória do sistema. A função da memória em tais sistemas é manter uma biblioteca de casos, representados e organizados, de tal forma que para um problema apresentado, um caso apropriado pode ser recuperado e seu raciocínio a ele aplicado.

6.3 O Ciclo do RBC

De modo geral, o ciclo do RBC pode ser descrito por quatro processos:

1. Recuperação de casos

A tarefa de recuperação inicia com uma descrição parcial do problema, e finaliza quando o “*best match*” do caso prévio foi encontrado. Suas subtarefas são: identificar características, inicializar as combinações, buscar e escolher, nessa ordem. A tarefa de identificação acontece com um conjunto de problemas relevantes descritivos, o objetivo da tarefa de combinações é a de retornar um conjunto de casos que é suficientemente similar ao novo caso, dado um limiar de similaridade de algum tipo, e a tarefa de escolha trabalha sobre este conjunto de casos e seleciona o “*best match*” [45].

2. Reutilização do Caso

O objetivo deste passo é examinar um conjunto de casos relevantes na interpretação ou na solução a ser gerada no passo seguinte. A reutilização da solução do caso recuperado no contexto do novo caso enfoca dois aspectos: (a) as diferenças entre o caso atual e caso passado e (b) que parte do caso recuperado pode ser transferido ao novo caso.

3. Revisão do Caso

Quando uma solução do caso gerada pela etapa de Reutilização não é correta, uma oportunidade por aprendizado de falhas surge. Esta etapa é chamada revisão de casos e consiste de duas tarefas: (1) avaliar o caso solução gerado por Reutilização. Se tem sucesso, o aprendizado é desde o sucesso, (2) caso contrário consertar o caso solução utilizando o conhecimento do domínio específico.

4. Retenção do Caso - Aprendizado

Este é o processo de incorporação do que é útil para reter do episódio do novo problema resolvido dentro do conhecimento existente. O aprendizado desde sucessos ou falhas das soluções propostas é desencadeada pelo resultado da avaliação e concertos possíveis. Isto envolve escolha de quais informações do caso para reter, em que forma retê-las, como indexar o caso para posteriores recuperações de problemas similares, e como integrar o novo caso na estrutura da memória.

As etapas precedentes descrevem como é o ciclo básico da máquina de inferência de um sistema baseado em casos (ver Figura 6.3)

6.4 O Sistema Especialista para Diagnóstico Médico por Analogia Nebulosa (SEDMAN)

O interesse é modelar o raciocínio do especialista clínico fazendo ao mesmo tempo o tratamento da imprecisão nos dados clínicos que ele utiliza.

Do estudo feito até agora acredita-se que o médico durante sua atividade profissional utiliza diversas formas e métodos de raciocínio quando encontra-se frente a um problema, mas ele, no decorrer do tempo e através de observações, induções, e

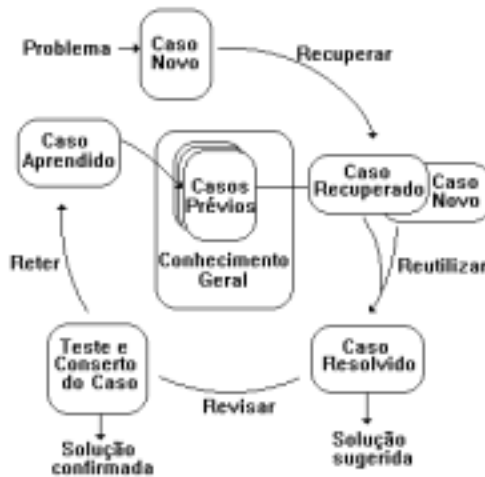


Figura 6.3: O ciclo do Raciocínio Baseado em Casos

generalizações, chega a especializar-se e após acumular experiências (aprendizado) ele fará analogia.

Dentro desse contexto e baseados na hipótese que o raciocínio do especialista médico para o diagnóstico é por analogia, lembrança de casos já conhecidos, e que esses casos encontram-se armazenados na sua memória em uma estrutura de dados qualitativos, isto é como variáveis linguísticas, propõe-se portanto utilizar:

- O método nebuloso para a representação das variáveis linguísticas representando assim a imprecisão nos dados clínicos, e
- O paradigma do Raciocínio Baseado em Casos da IA para modelar o raciocínio do especialista.

Utiliza-se o RBC porque além de representar melhor o raciocínio do especialista, não apresenta dificuldades no tratamento da imprecisão como no caso dos sistemas baseados em regras os quais pelo longo encadeamento de regras converte a propagação da imprecisão na propagação de ambiguidades no sistema.

A figura 6.4 mostra a estrutura do sistema desenvolvido que foi denominado **SEDMAN** (**S**istema **E**specialista para **D**iaagnóstico **M**édico por **A**nalogia **N**ebulosa). O sistema foi desenvolvido na seguinte plataforma: microcomputador IBM PC-compatível (processador 486DX), 8 *MBytes* de memória RAM, aproximadamente 3 *MBytes* de disco rígido, monitor colorido com resolução de 800 x 600 *pixels* em

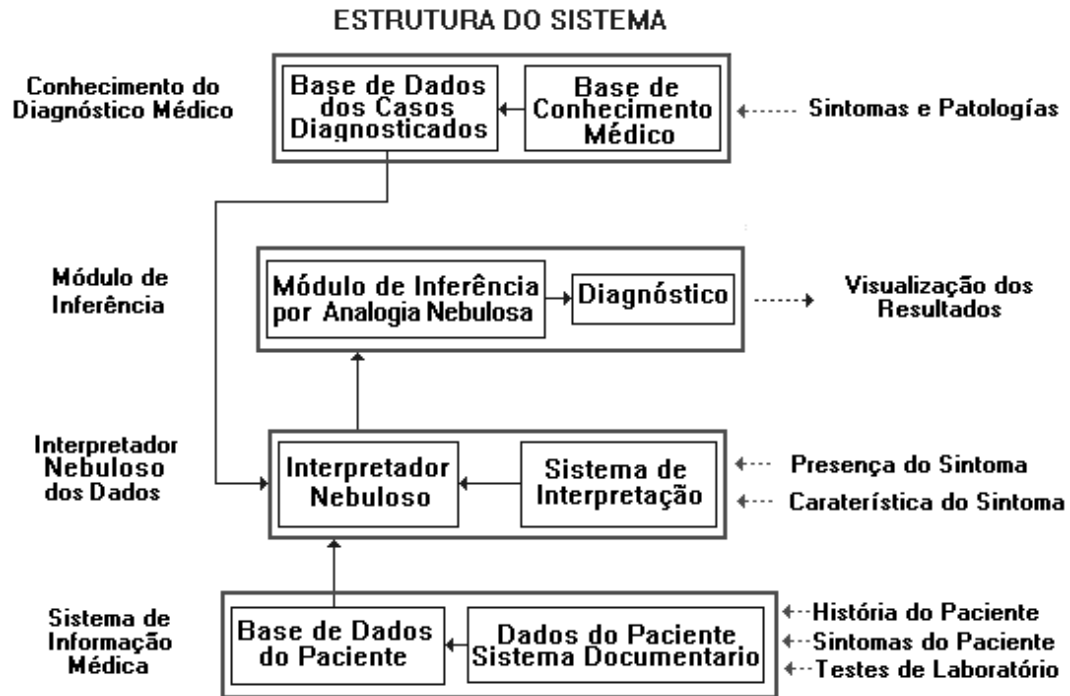


Figura 6.4: Estrutura do Sistema Especialista para Diagnóstico Médico por Analogia Nebulosa (SEDMAN)

256 cores e *mouse* serial. O sistema é executado em ambiente Microsoft Windows, versão 3.1 sobre o sistema operacional DOS 6.2.

O sistema todo foi desenvolvido utilizando o Visual Basic 3.0 devido ao ambiente amigável e a facilidade de construção de interfaces de apresentação. O sistema está constituído pelas seguintes etapas[20]:

1. Conhecimento do Diagnóstico Médico
2. Aquisição do Conhecimento Médico
3. Sistema de Informação Médica
4. Interpretador Nebuloso dos Dados
5. Módulo de Inferência
6. Interface com o Usuário

6.4.1 Representação do Conhecimento Médico

A primeira etapa na implementação de sistemas baseados no conhecimento é a definição da forma de representação do conhecimento. A partir desta etapa é que se vai definir as outras etapas do sistema tais como: a maneira de obter o conhecimento do especialista e como serão operadas para obter os resultados. Com estas considerações, e tendo presente que o interesse encontra-se na imprecisão dos dados, cada doença vai ser representada por um vetor de sintomas, onde cada sintoma encontra-se como variável linguística.

A cada sintoma poderia atribuir-se um peso para representar a importância do sintoma em relação a uma doença em particular, mas em nosso caso esse valor é considerado como a unidade $\beta = 1$.

6.4.2 Aquisição do Conhecimento Médico

A aquisição de conhecimento é feita de modo a produzir a base de conhecimento do sistema, onde a base é constituída pelo grupo de casos das doenças que o sistema é capaz de diagnosticar. Assim, o conhecimento no sistema fica em conjuntos de vetores representativos de n casos para cada doença. Aqui definiu-se as informações úteis para o diagnóstico:

- Dados pessoais do paciente.
- Sintomas característicos das doenças Lupus e Artrite (conforme ao Capítulo 5).
- Resultados de exames laboratoriais e complementares.

6.4.3 Sistema de Informação Médica

Esta etapa contém a base de dados (dados relevantes para o diagnóstico) do caso novo que foi extraída dos dados gerais fornecidos pelo paciente durante a anamnese, o ingresso de um caso novo a diagnosticar, chama a base de casos da doença mais similar através de um diagnóstico diferencial (figura 6.5), o novo caso chama da Base de Casos os casos mais similares [21].

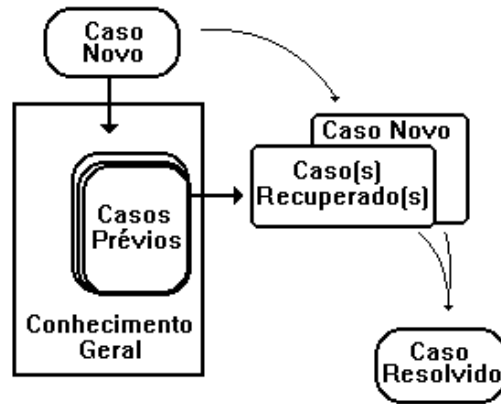


Figura 6.5: Ativação da base de casos pelo caso novo

6.4.4 Interpretador Nebuloso dos Dados

O interpretador nebuloso pega os vetores de sintomas dos dados de entrada que se encontram como variáveis linguísticas. Através do sistema de interpretação onde encontram-se as funções de pertinência nebulosa para as variáveis de entrada (sintomas) obtém o valor nebuloso que representa a cada dado, formando assim um vetor característico para cada caso com valores nebulosos. Estes valores representam o grau de pertinência de cada sintoma a seu conjunto nebuloso. Por exemplo, tem-se a função de pertinência para o sintoma “Febre” (figura 6.6).




Figura 6.6: Função de pertinência para o sintoma “Febre”

Os valores obtidos serão aqueles que correspondem ao valor da função de pertinência correspondente ao valor numérico ou linguístico de cada sintoma.

6.4.5 Módulo de Inferência por Analogia Nebulosa

Contém os vetores representativos do caso novo e dos casos conhecidos, e é através de uma medida de distância que ele determina o caso ou casos mais similares, seja Q o paciente que deseja-se diagnosticar; P_j representa aos pacientes da base de casos já diagnosticados, onde $j = 1, 2, \dots, n$ (n é o número de casos conhecidos), S_i representa o sintoma que caracteriza a doença, onde $i = 1, 2, \dots, m$ (m é o número de sintomas). O nível de intensidade dos sintomas está dado pelos conjuntos nebulosos:

$$Q_i = \{\mu_{q_1}/s_1, \mu_{q_2}/s_2, \dots, \mu_{q_m}/s_m\}$$

$$P_{ji} = \{\mu_{p_{j1}}/s_1, \mu_{p_{j2}}/s_2, \dots, \mu_{p_{jm}}/s_m\}$$

onde os s_i são valores numéricos achados através das funções de pertinência contidas no sistema de interpretação, esses valores numéricos representam as variáveis linguísticas expressas pelo paciente na caracterização dos sintomas ou observadas pelo clínico. Logo o sistema compara os conjuntos nebulosos de sintomas do paciente novo (Q) com os pacientes da base de casos já diagnosticados (P_j), quando:

$$\mu_{p_{ji}} \approx \mu_{q_i}$$

$$\forall i, j \mid 1 \leq i \leq m \text{ e } 1 \leq j \leq n$$

$$\text{Onde: } \mu_{p_i} \text{ e } \mu_{q_j} \in [0, 1]$$

pode ser dito que Q é similar a P com um grau de similaridade medido com uma métrica de distância adequada. Se algum sintoma s_x não está presente, logo μ_{p_x} ou $\mu_{q_x} = 0$.

Tomando a distância Manhattan que esta apropriadamente modificada pelos pesos que representam a importância relativa de cada sintoma, tem-se:

$$D_t(\mu_{p_{i,j}}, \mu_{q_i}) = \sum_{i,j=1}^{m,n} \mid \beta_i(\mu_{p_{i,j}} - \mu_{q_i} \mid$$

onde $t = 1, 2, 3, \dots, k$ (k é o número de doença, β_i especifica a importância de cada sintoma s_i no diagnóstico de cada doença. Os pesos β_i são tão importantes que foi estudada por Lopes [51] utilizando algoritmos genéticos, mas aqui é tomado de valor unitário. A doença candidata é aquela onde a medida de similaridade é a do valor mínimo. O raciocínio feito desta maneira é por analogia, os conjuntos comparados Q e P são subconjuntos nebulosos dos conjuntos abruptos S (sintomas), e se chama **Raciocínio por analogia nebulosa**[22]

6.4.6 Interface com o Usuário

O desenvolvimento do sistema protótipo fez-se considerando que a interface homem-máquina deve ser amigável, por razões de ergonomia (o que é feito pelo homem deve servir a ele com comodidade e sem maiores dificuldades), além disso porque espera-se que o protótipo possa em uma etapa posterior ser melhorada.

A entrada de dados requerida do operador é simples, o menu foi concebido para poder utilizar tanto o *mouse* quanto o teclado, já que, em alguns casos, como o número do prontuário, se é obrigado a usar o teclado. Os sintomas são de dois tipos: os dicotômicos (sim ou não) e os de multivalores (variáveis linguísticas), neste último caso tem-se setas que permitem escolher a variável linguística mais representativa do sintoma.

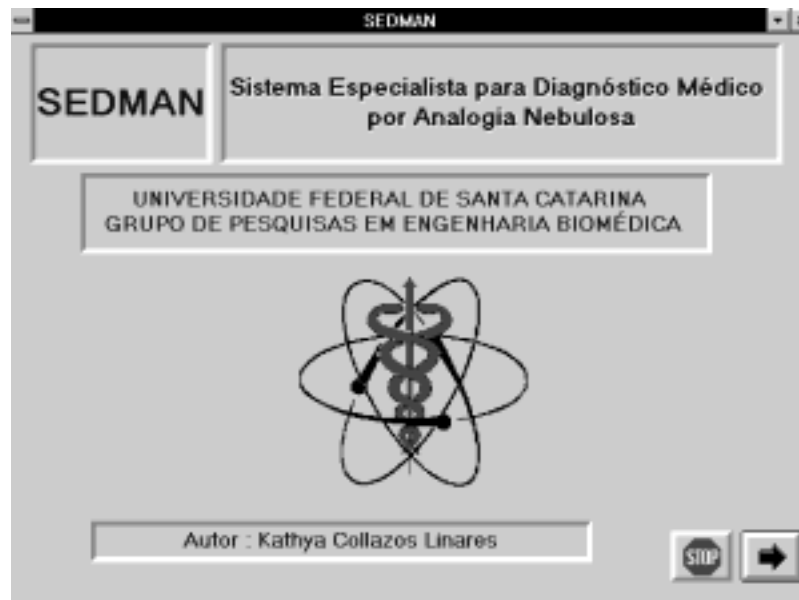


Figura 6.7: Tela de apresentação do sistema **SEDMAN**

A figura 6.8 mostra a tela de apresentação do sistema, como este é um sistema protótipo, ele tem na sua base de dados somente duas doenças a diagnosticar: Artrite reumatóide e Lupus eritematoso.

A partir desta tela de apresentação do sistema SEDMAN é possível acessar a tela principal do sistema. Na tela principal (figura 6.9) tem-se na parte superior o menu do sistema, do qual é possível acessar as seguintes funções:

- Arquivo

- Salvar: tem a finalidade de guardar os dados fornecidos pelo paciente e tê-los como arquivos de história clínica do paciente (figura 6.10).
 - Carregar: permite acessar a base de pacientes disponível e mostrá-los na tela (figura 6.11).
- Paciente
 - Prontuário: serve como entrada de dados para um novo caso clínico o qual vai ser diagnosticado pelo sistema SEDMAN.
 - Incluir paciente: permite incluir na base de dados um novo paciente (caso).
 - Lista de pacientes: mostra a lista dos pacientes que estão sendo atendidos, ou do arquivo de pacientes que foi acessado, e pode-se também carregar o prontuário do paciente escolhido (figura 6.12).
 - Ajuda

Permite acessar o sistema de ajuda que na versão atual fornece ao usuário informação sobre as funções do sistema.
 - Diagnosticar

Permite fornecer o diagnóstico mais similar. O caso atual pode também ser incluído na base de dados.
 - Parar (“Stop”)

Permite sair do sistema.

O número de prontuário é que será utilizado como indexador do registro da base de casos. O nome do paciente será utilizado como indexador em ordem alfabética para mostrar a lista de pacientes. Em todas as telas há sempre a opção de seguir para a próxima tela ou voltar para a tela anterior, ou abandonar o sistema.

A figura 6.13 mostra a tela de entrada de dados seguintes: sintomas relatados pelo paciente, sinais observados pelo médico durante o exame clínico, e resultado de exames laboratoriais e complementares (quando disponíveis).

Após a entrada dos dados, o usuário poderá acionar o botão de diagnosticar, ativando o módulo de inferência por analogia nebulosa para fornecer o diagnóstico (figura 6.14). Este diagnóstico é achado pelo maior grau de similaridade considerando um α de corte que no sistema é de 0.5.



Figura 6.8: Tela principal do sistema SEDMAN

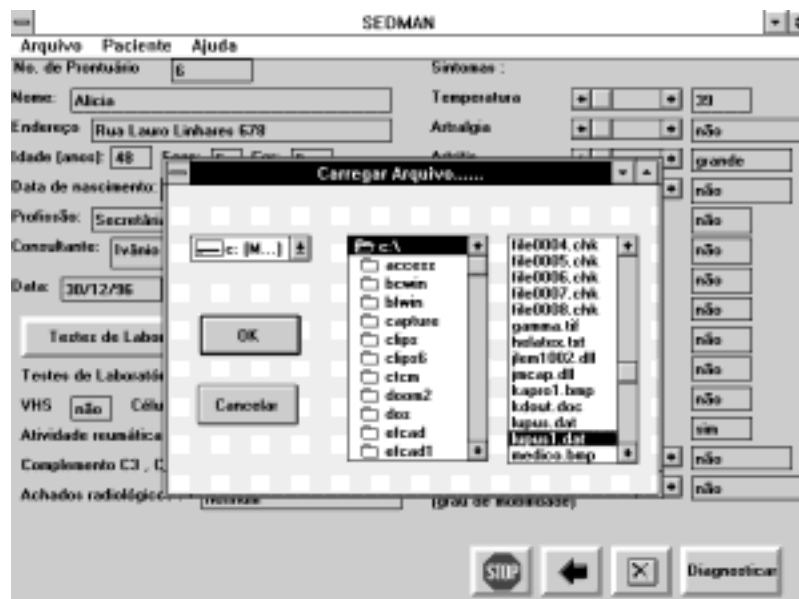


Figura 6.9: Tela para carregar arquivos no sistema SEDMAN



Figura 6.10: Tela para guardar arquivos no sistema SEDMAN



Figura 6.11: Tela para mostrar a lista de pacientes no sistema SEDMAN

SEDMAN

Arquivo Paciente Ajuda

No. de Prontuário: 15

Nome: Leila Guimarães

Endereço: Servidão Costa 76

Idade (anos): 40 Sexo: F Cor: B

Data de nascimento: 12/05/1950

Profissão: Costureira

Consultante: SEDMAN

Data: 20/12/96

Testes de Laboratório Sintomas:

Testes de Laboratório

VHS: não Células LE: não IgM, IgG: não

Atividade reumática: não Mucoproteínas: não

Complemento C3, C4: não

Achados radiológicos: nenhum

Diagnóstico possível: Trata-se de Artrite sistêmica caso (s) 4

Sintomas:

Temperatura: 38,5

Artralgia: intensa

Artrite: grande

Myalgia: não

Nódulos subcutâneos: sim

Erupção em asa de borboleta: não

Alopecia: não

Fotosensibilidade: não

Fenômeno de Raynaud: não

Manifestações pulmonares: não

Manifestações neurológicas: sim

Manifestações renais: sim

Mão reumatoide: moderada

Rigidez matinal (grau de mobilidade): muito pouco

STOP ← × Diagnosticar

Figura 6.12: Tela para entrada dos dados do paciente no sistema **SEDMAN**

SEDMAN

Arquivo Paciente Ajuda

No. de Prontuário: 18

Nome: Carlos Da Silva

Endereço: Rua Desembargador Vitor Lima 214

Idade (anos): 30 Sexo: M Cor: B

Data de nascimento: 03/04/1966

Profissão: Encasador

Consultante: SEDMAN

Data: 20/12/96

Testes de Laboratório Sintomas:

Testes de Laboratório

VHS: não Células LE: não IgM, IgG: não

Atividade reumática: não Mucoproteínas: não

Complemento C3, C4: não

Achados radiológicos: nenhum

Diagnóstico possível: Trata-se de Lupus sistêmico caso (s) 7

Sintomas:

Temperatura: 38

Artralgia: não

Artrite: não

Myalgia: não

Nódulos subcutâneos: não

Erupção em asa de borboleta: sim

Alopecia: sim

Fotosensibilidade: sim

Fenômeno de Raynaud: sim

Manifestações pulmonares: não

Manifestações neurológicas: não

Manifestações renais: não

Mão reumatoide: não

Rigidez matinal (grau de mobilidade): não

STOP ← × Diagnosticar

Figura 6.13: Tela de diagnóstico fornecido pelo sistema **SEDMAN**

Capítulo 7

Discussão e Conclusões

7.1 Análise dos resultados

Os resultados obtidos com o sistema **SEDMAN**, foram os esperados, isto é, o sistema achou o diagnóstico certo pela similaridade com a base de casos que tem, mas deve-se ressaltar ao mesmo tempo, que a dificuldade de obter informações dos especialistas na área, fez com que a base de casos do sistema seja mesmo uma base só de teste primário. Não é possível dado o baixo número de casos tirar conclusões com respeito ao desempenho.

A respeito do tratamento da imprecisão nos sintomas relatados pelo paciente com variáveis linguísticas pode-se dizer que é mais próximo da linguagem utilizada pelo especialista, do que os sistemas dicotômicos que só permitem dois estados possíveis aos sintomas.

O sistema apesar de não ter todos seus campos preenchidos pode levar a resultados, e isto também era esperado por tratar-se de um sistema baseado em casos os quais podem trabalhar com informação incompleta, à diferença dos sistemas probabilísticos.

7.2 Discussão

A principal expectativa no desenvolvimento de um SE é se ele chegará a ser utilizado na prática pelo não especialista humano. Mas os pontos contra a utilização de SE para apoio à decisão médica são muitos. As pesquisas feitas no GPEB com o objetivo de ter uma metodologia de avaliação de SE na área médica propõe o ciclo protótipo-retorno-reimplantação como uma forma de desenvolvimento de SEs

mais práticos do que teóricos e ao mesmo tempo mantendo uma interação entre o engenheiro do conhecimento e o especialista médico [62]. Mas a interação engenheiro-médico, ainda não tem atingido o nível desejado. De fato as bases de conhecimento entre ambos são diferentes, os preconceitos de um lado do médico em acreditar que o engenheiro só faz raciocínios sobre valores exatos e do engenheiro em acreditar que o médico faz raciocínios não demonstrativos pela lógica, impedem a comunicação entre eles.

Nesse contexto, tem-se que:

- As dificuldades de comunicação com especialistas na área dificulta o desenvolvimento deste tipo de sistemas, o que faz uma necessidade da área da inteligência artificial interagir mais com os clínicos.
- A analogia baseada na similaridade de casos já conhecidos é uma boa opção dado que muitos pesquisadores demonstraram que este processo cognitivo é muito empregado na resolução de problemas e muito em particular empregado pelos especialistas clínicos em uma sessão de diagnóstico.
- A utilização da analogia abre um caminho alternativo no fracasso de modelos específicos para a análise de doenças na área médica, cada caso é único, mas ele pode ser comparado a outro o que não quer dizer que ele será modelado por outro.

7.3 Conclusões

O esforço foi dirigido para demonstrar que é possível desenvolver sistemas que trabalhem com variáveis linguísticas e não precisam ter valores exatos para chegar a resultados. Finalmente, pode-se concluir que:

- A lógica nebulosa é ótima para representar a imprecisão nos dados clínicos. A utilização de variáveis linguísticas é mais realista do que um sistema dicotômico de sim ou não.
- O sistema pode ser olhado de modo diferente pelos especialistas, posto que ele não tenta substituí-los senão ele pode servir como uma memória adicional e pode fazê-lo lembrar de casos não comuns.

- O sistema é simplesmente um protótipo o qual tenta mostrar um caminho a seguir na área da inteligência artificial, e ao mesmo tempo continua na linha do GPEB de construção de protótipos com mais clareza de objetivos do que intenções de sistemas que finalmente terminam sem ser utilizados.
- O uso de la lógica nebulosa e o raciocínio por analogia podem facilitar o desenvolvimento de SE de apoio à decisão em Medicina.

7.4 Trabalhos Futuros

As possibilidades de trabalhos futuros relacionados ao estudo feito nesta dissertação, envolvem raciocínio por analogia, imprecisão e lógica nebulosa. Os sistemas baseados em RBC tem emergido há relativamente pouco tempo, mas este paradigma da IA tem aberto muitas expectativas, o que sugere explorar mais as vantagens oferecidas por ele, tais como:

- O aprendizado, que pode ser menos complexo. O RBC não precisa de um modelo causal, ou um conhecimento profundo do domínio.
- Explicação dos resultados a partir de casos individuais. A explicação que pode ser simples de gerar e mais satisfatórias do que as cadeias de regras geradas por sistemas simbólicos baseados em regras. Ressalta-se ainda que o RBC difere dos sistemas conexionistas que não podem fornecer explicações em todo seu processo.
- Aquisição de conhecimento é muito mais fácil do que em outros métodos de aprendizado, os quais geralmente precisam ter quantidades de conhecimento disponíveis antes que o processo de aprendizagem seja útil.
- Representação do raciocínio do especialista, o RBC parece estar ligado à psicologia cognitiva à diferença dos sistemas baseados em regras, os que aparentemente baseiam-se em teorias comportamentais. O estudo destas questões permitirá desenvolver modelos de raciocínio para que a máquina haja como o humano e não modelar o raciocínio humano como se fosse uma máquina. Portanto, faz-se necessário o estudo da psicologia cognitiva para uma melhor compreensão do raciocínio humano.

A lógica nebulosa é uma ferramenta poderosa no tratamento da imprecisão. A flexibilidade na representação de variáveis linguísticas em linguagem natural a fazem elegível em sistemas de apoio à decisão em medicina. No entanto ainda tem-se dificuldade de extrair do especialista a qualificação dos dados nebulosos com os quais ele trabalha, que se que supõe ele avalia implicitamente ao resolver um problema, mas que não consegue explicitar. Assim, tem-se ainda por estudar: o fator “beta” de ponderação (peso ou força) dos sintomas segundo a doença.

Referências Bibliográficas

- [1] AAMODT, AGNAR; PLAZA, ENRIC. Case-based reasoning: foundational issues, methodological variations, and systems approaches. *AICom- Artificial Intelligence Communications*, v.7, n.1, 1994.
- [2] ADLASSNIG, KLAUS-PETER. Fuzzy set theory in medical diagnosis. *IEEE Trans. on Systems, Man and Cybernetics*, v.16, n.2, p.260–265, march/april 1986.
- [3] ASHLEY, KEVIN D. Assessing Similarities Among Cases a Position Paper. *Proceedings: Case-Based Reasoning Workshop*, may 31 - june 2, 1989, Florida(USA), p. 72–76.
- [4] ASHLEY, KEVIN D. Reasoning with cases and hypotheticals in HYPO. *Int. J. Man-Machine Studies*, v. 34, p. 753–796, 1991.
- [5] APPELBAUM, L.; RUSPINI, E.H. ARIES: An approximate reasoning inference engine. *Approximate Reasoning in Expert Systems*, Gupta et al. (eds.), Amsterdam: Elsevier Science Publishers, 1985, p. 745–755.
- [6] AZEVEDO, F.M.; BARRETO, J.M.; EPPRECHT, E.K. et al. Two approaches in case-based connectionist expert systems *Proceedings: IASTED International Conference - Artificial Intelligence Applications and Neural Networks*, july 1-3, 1991, Zurich(Switzerland), p. 13 –17.
- [7] AZEVEDO, FERNANDO M. “Contribution to the study of neural networks in dynamical expert system” - PhD Thesis. *Institut d’Informatique, FUNDP*. Namur(Belgium), 1993.
- [8] BAREISS, RAY. *Exemplar-Based Knowledge Acquisition*. San Diego, CA: Academic Press, 1989.

- [9] BARLETA, RALPH. An Introduction to case-Based Reasoning. *AI Expert*, p.43–49, august 1991.
- [10] BARRETO, JORGE. A topological model for qualitative time. *Proceedings: IASTED Artificial Intelligence Application and Neural Networks*, June 25–27, 1990, Zurich (Switzerland), p.16–21.
- [11] BARRETO, JORGE; AZEVEDO, FERNANDO. Connectionist expert systems as medical decision aid. *Artificial Intelligence in Medicine*, v. 5 p.1–9, 1993.
- [12] BARRETO, JORGE. *Expert systems in Biomedicine*. Université Catholique de Louvain, Faculté de Médecine - Faculté des Sciences Appliquées, Certificat en Informatique Biomédicale, Bruxelles (Belgium), 1993.
- [13] BARRETO, JORGE. *Logica Nebulosa*. Universidade Federal de Santa Catarina, Centro Tecnológico, Departamento de Engenharia Elétrica, Grupo de Pesquisas em Engenharia Biomédica. Florianópolis (Brasil), 1995.
- [14] BEN-BASSAT, M.; CARLSON, R.; PURI, V.; et al. Pattern-based interactive diagnosis of multiple disorders: The MEDAS system. *IEEE Transactions Pat. Anal. Mach. Intel. (PAMI)*, v. 2, n.2, p.148, 1980.
- [15] BRASIL, Lourdes M. “Aquisição de conhecimento aplicada ao diagnóstico de epilepsia” - Dissertação de Mestrado. *Universidade Federal de Santa Catarina*. Florianópolis (Brasil), 1994.
- [16] BUCHANAN, B. G.; SHORTLIFFE, E. *Rule-Based Expert Systems: The MYCIN Experiments of the Stanford Heuristic Programming Project*. Reading MA: Addison-Wesley, 1984.
- [17] BYLANDER, T.; WEINTRAUB, M.; SIMON, S. QUAWDS: Diagnosis using different models for different subtasks. *Second Generation Expert Systems*, J-M David et al. (eds.), Berlin: Springer-Verlag, 1993, p. 110–130.
- [18] CALLUPE, ROCIO; BARRETO, JORGE ; NASSAR, SILVIA. Aplicaciones de aprendizaje de machine learning em sistemas expertos na área médica. A ser publicado em: *Anales del VII Simposio Latinoamericano de Ingeniería Biomédica*, 9-13 outubro, 1996, Bucaramanga (Colombia).

- [19] CELLIER, FRANCOIS. *Continuous System Modelling*. New York: Springer-Verlag, 1991.
- [20] COLLAZOS, KATHYA ; BARRETO, JORGE ; NASSAR, SILVIA. Raciocínio por analogia fuzzy para diagnóstico médico. *Anais: Fórum Nacional de Ciência e tecnologia em Saúde*, 13-17 outubro, 1996, Campos do Jordão(Brasil), v.2, p.713–714.
- [21] COLLAZOS, KATHYA ; BARRETO, JORGE ; NASSAR, SILVIA. Lógica fuzzy para el tratamiento de la incerteza en el raciocínio médico. A ser publicado em: *Anales del VII Simposio Latinoamericano de Ingeniería Biomédica*, 9-13 outubro, 1996, Bucaramanga(Colombia).
- [22] COLLAZOS, KATHYA ; BARRETO, JORGE ; NASSAR, SILVIA. Fuzzy Analogical Reasoning for medical Diagnosis. *CD-ROM Proceedings: 3rd. Internet World Congress on Biomedical Science '96*, december 9-20, 1996, Riken(Japan), DH0408.
- [23] COSSERMELLI, WILSON. *Afeções Difusas do Tecido Conetivo*. São Paulo: Editora da Universidade de São Paulo, 1966.
- [24] DEGOULET, P.; FIESCHI, MARIUS. *Informatique Médicale*. Paris: MASSON, 1994.
- [25] DE NEYER, MARC. “Contribution to fuzzy controller analysis and study of several fuzzy control systems” - PhD Thesis (Preliminary version). *Université Catholique de Louvain*. Bruxelles(Belgium), 1996.
- [26] DE SÉZE, S. *Connaissance Elementaire du Rheumatisme*. Paris: Expansion Scientifique Française, 1956.
- [27] DIXON, A.S. *Prefácio. In Progress in Clinical Rheumatology*. Londres: J. and A. Churchill Ltd., 1965.
- [28] DUBOIS, DIDIER; PRADE, HENRI. *Fuzzy Sets And Systems Theory and Applications*. New York: Academic Press, 1980.
- [29] DUBOIS, DIDIER; PRADE, HENRI. Combination and propagation of uncertainty with belief functions. *Proceedings: IJCAI '85*, p. 111–113, 1985.

- [30] FIESCHI, MARIUS. *Intelligence Artificielle em Médecine des systèmes experts*. Paris: MASSON, 1984.
- [31] GARCIA, RENATO. “Técnicas de inteligência artificial aplicadas ao apoio à decisão médica na especialidade de anestesiologia” - Tese de Doutorado. *Universidade Federal de Santa Catarina*. Florianópolis(Brasil), 1992.
- [32] GIARRATANO, JOSEPH. *Experts Systems Principles and Programming*. Boston: PWS-KENT Publishing Company, 1989.
- [33] GORDON, Jean; SHORTLIFFE, EDWARD. The Dempster-Shafer theory of evidence. *Rule-Based Expert Systems*, B. Buchanan, E. Shortliffe (eds.), 1985, p. 272–292.
- [34] HAMMOND, K.. CHEF: A model of case-based planning. *Proceedings: National Conference on Artificial Intelligence*, p. 267–271, 1986.
- [35] HARTMUT KOPPITKE, BRUNO et al. Um sistema inteligente de apoio à decisão estratégica baseado em inferência probabilística. A ser publicado em: *Anais do VII Congresso Nacional de Investigação Operacional*, 1-3 abril, 1996, Aveiro(Portugal).
- [36] HECKERMAN DAVID; WELLMAN MICHAEL P. Bayesian Networks. *Communications of the ACM*, v. 38, n.3, p.27–30, march 1995.
- [37] HERNANDEZ V., WALTER. “Simulação Cognitiva da tomada de decisão em situações complexas: Modelagem do Raciocínio Humano por Meio de Casos” - Tese de Doutorado. *Universidade Federal de Santa Catarina*. Florianópolis(Brasil), 1994
- [38] HOLLAND, JOHN; HOLYOAK, KEITH; NISBETT, RICHARD; THAGARD, PAUL. “*Induction*” *Processes of Inference, Learning and Discovery*. Cambridge: The MIT Press, 1993.
- [39] HOLLANDER, J. L. *Introduction to Arthritis and Rheumatic Diseases*. Filadelfia: Lea and Febiger, 1966.
- [40] HUDSON,D.; COHEN, M.; DEEDWANIA, P. EMERGE: An expert system for chest pain analysis. *Approximate Reasoning in Expert Systems*, Gupta et al. (eds.), Amsterdam: Elsevier Science Publishers, 1985, p. 705–718.

- [41] HUDSON, DONNA L.; COHEN, MAURICE E. Fuzzy logic in medical expert systems. *IEEE Magazine in Medicine and Biology*, p.693–698, novembro/dezembro 1994.
- [42] KLIR, GEORGE; YUAN B. *Fuzzy Sets and Fuzzy Logic*. New Jersey: Prentice-Hall, 1995.
- [43] KOLODNER, J. Extending problem solver capabilities through case-based inference. *Proceedings: 4th. International Workshop on Machine Learning*, p. 167–178, 1987.
- [44] KOLODNER, JANET; RISSLAND, EDWINA; WALTZ, DAVID for DARPA. Case-based reasoning. *Proceedings: Case-Based Reasoning Workshop*, may 31 - june 2, 1989, Florida(USA), p.1–13.
- [45] KOLODNER, JANET. Judging wich is the “best” case for a case-based reasoner. *Proceedings: Case-Based Reasoning Workshop*, may 31 - june 2, 1989, Florida(USA), p.77–81.
- [46] KOLODNER, JANET. Improving humam decision making through case-based decision aiding. *AI Magazine*, v.12, n.2, p.52–68, 1991.
- [47] KOLODNER, JANET; MARK, WILLIAM. Case-Based Reasoning. *IEEE Expert*, v.7, n.5, p.5–6, october 1992.
- [48] KULIKOWSKI, CASIMIR A. History and development of artificial intelligence methods for medical decision making. *The Biomedical Engineering Handbook*, p.2681–2695, 1995.
- [49] LI SHIH MIN. “Sistema baseado em conhecimento para detecção e classificação de crises epilépticas” - Dissertação de Mestrado. *Universidade Federal de Santa Catarina*. Florianópolis(Brasil), 1994.
- [50] LIMA, W.C.; BARRETO, J.M. Inteligência Artificial. *Ciência Hoje*, v. 7, n.38, p.51–56, dezembro 1987.
- [51] LOPES, HEITOR S. “Analogia e aprendizado evolucionário: aplicação em diagnóstico clínico” - Tese de Doutorado. *Universidade Federal de Santa Catarina*. Florianópolis(Brasil), 1994.

- [52] McCARTHY, DANIEL J.; KOOPMAN, WILLIAM J. *Arthritis and Allied Conditions*. Lea & Febiger Editor, v.1, 1993.
- [53] McCARTHY, DANIEL J.; KOOPMAN, WILLIAM J. *Arthritis and Allied Conditions*. Lea & Febiger Editor, v.2, 1993.
- [54] MENDEL, JERRY M. Fuzzy logic systems for engineering: A tutorial. *Proceedings of the IEEE*, v.83, n.3, p.345–377, march 1995.
- [55] MILLER, A.; POPLE, H. et al. Internist-1: An experimental computer-based diagnostic consultant for general internal medicine. *Readings in Medical Artificial Intelligence*, William J. Clancey, Edward H. Shortliffe (eds.), Addison-Wesley Publishing Company, 1984, p. 190–209.
- [56] MINSKY, Marvin. A Framework for Representing knowledge. *The Psychology of Computer Vision*, Patrick H. Winston editor, New York: McGraw-Hill Book Company, 1975.
- [57] NASSAR, SILVIA M. “Sistema estatístico inteligente para apoio a pesquisas médicas” - Tese de Doutorado. *Universidade Federal de Santa Catarina*. Florianópolis(Brasil), 1995.
- [58] NIEVOLA, Júlio C. “Sistema especialista para auxílio ao diagnóstico médico de icterícia” - Dissertação de Mestrado. *Universidade Federal de Santa Catarina*. Florianópolis(Brasil), 1988.
- [59] NIEVOLA, Júlio C. “Sistema inteligente para auxílio ao ensino em traumatologia crânio-encefálica” - Tese de Doutorado. *Universidade Federal de Santa Catarina*. Florianópolis(Brasil), 1995.
- [60] NII, H.; AIELLO, N. AGE: A knowledge-based program for building knowledge-based programs. *Proceedings: 6th. IJCAI*, p.645–655, 1979.
- [61] OSHITA, SHUZO; NAKAKIMURA, KAZUHIKO; SAKABE, TAKEFUMI. Hypertension control during anesthesia. *IEEE Magazine in Medicine and Biology*, p.667–670, november/december 1994.
- [62] PELLEGRINI, GISELE F. “Proposta de uma metodologia de avaliação para sistemas especialistas” - Dissertação de Mestrado. *Universidade Federal de Santa Catarina*. Florianópolis(Brasil), 1995.

- [63] PAUKER, S.; GORRY, G.; KASSIRER, J. Towards the simulation of clinical cognition: Taking a present illness by computer. *American Journal of Medicine*, v. 60, p.981, 1976.
- [64] PERL, JUDEA. *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference*. San Mateo, CA: Morgan Kaufmann Publishers, 1988.
- [65] PIAGET, JEAN. *Seis Estudos de Psicologia*. Editora Forense, 1964.
- [66] POLYA, GEORGE. *Mathematics and Plausible Reasoning Induction and Analogy in Mathematics*. New Jersey: Princenton University Press, 1990.
- [67] POLYA, GEORGE. *Mathematics and Plausible Reasoning Patterns of Plausible Inference*. New Jersey: Princenton University Press, 1990.
- [68] POPLE, H.; MYERS, J.; MILLER R. DIALOG: A model of diagnostic logic of internal medicine. *Proceedings: 4th. IJCAI*, p.848–855, 1975.
- [69] RAMIREZ, AURORA. “Sistema inteligente para treinamento do controle da infecção hospitalar” - Dissertação de Mestrado. *Universidade Federal de Santa Catarina*. Florianópolis(Brasil), 1991.
- [70] RAMIREZ, AURORA. “Um sistema de ensino inteligente via sociedade de multi-agentes aplicado ao diagnóstico de epilepsia” - Tese de Doutorado. *Universidade Federal de Santa Catarina*. Florianópolis(Brasil), 1996.
- [71] REDMOND, M. Learning from others experience: creating cases from examples. *Proceedings: Case-Based Reasoning Workshop*, may 31 - june 2, 1989, Florida(USA), p.309–312.
- [72] RICH, ELAINE; KNIGHT, KEVIN. *Inteligência Artificial*. São Paulo: MAKRO Books do Brasil Editora, 1993.
- [73] SANCHEZ, E. Medical diagnosis and composite fuzzy relations. *Advances in Fuzzy Set Theory and Applications*, M.M. Gupta, R.K.Radage, R.R. Yager (eds.), New York: North Holland, 1979, p. 421–433.
- [74] SCHANK, ROGER; ABELSON, R. *Scripts, plans, goals and understanding*. New Jersey: Lawrence Erlbaum Associates Publishers, 1977.

- [75] SCHANK, ROGER. *Dynamic Memory: A Theory of Learning in Computers and People*. Cambridge University Press, 1982.
- [76] SCHANK, ROGER; BLADE, STEPHEN B. The Future of Artificial Intelligence: Learning from Experience. *Applied Artificial Intelligence*, v.5, n.1, p.97–107, january/march 1991.
- [77] SEDA, HILTON. *Reumatologia*. Editora Cultura Médica, 1982.
- [78] SHAFER, GLENN. *A Mathematical Theory of Evidence*. Princeton University Press, 1976.
- [79] SHORTLIFFE, E. H. *MYCIN: Computer-based medical consultations*. New York: Elsevier Scientific , 1976.
- [80] SHORTLIFFE, E.H.; LAWRENCE, M.F.; HENRION, MAX; et al. Reasoning under uncertainty in medical decision-support. Disponível (via Internet em: <http://www.camis.stanford.edu/Reasonin.htm>), 1996.
- [81] SIGAKI, NANCY; AZEVEDO, FERNANDO; BARRETO, JORGE. Estudo do aprendizado baseado em casos em modelos de redes conexionistas - IAC (Interactive Activation and Competition). *Anais: Fórum Nacional de Ciência e tecnologia em Saúde*, 13-17 outubro, 1996, Campos do Jordão(Brasil), v.2, p.725–726.
- [82] SIMPSON, R. “A computer model of case-based reasoning in problem solving: An investigation in the domain of dispute mediation” - PhD Thesis. *Georgia Institute of Technology*. Atlanta(USA), 1985.
- [83] STANLEY, ROBBINS; ANGELL, MARCIA; KUMAR, VINAY. *Patologia Básica*. São Paulo: Atheneu Editora, 1986.
- [84] SZOLOVITS, PETER ; PAUKER, STEPHEN G. Categorical and probabilistic reasoning in medical diagnosis. *Readings in Medical Artificial Intelligence*, William J. Clancey, Edward H. Shortliffe (eds.), Addison-Wesley Publishing Company, 1984, p. 210–240.
- [85] THAGARD, PAUL; HOLYOAK, KEITH. Why indexing is the wrong way to think about analog retrieval. *Proceedings: Case-Based Reasoning Workshop*, may 31 - june 2, 1989, Florida(USA), p.36–40.

- [86] UMEYAMA, SINJI. The complementary process of fuzzy medical diagnosis and its proprieties. *Information Sciences*, v.38, p.229–242, 1986.
- [87] VAN MELLE, W. A domain-independent production rule system for consultation programs. *Proceedings: 6th. IJCAI*, p.923–925, 1979.
- [88] WEISS, S. et al. A model-based method for computer-aided medical decision making. *Artificial Intelligence*, v. 11, n.1–2, p.145–172, 1978.
- [89] WEISS, S.; KULIKOWSKI C. EXPERT: A system for developing consultation models. *Proceedings; 6th. IJCAI*, p.942–950, 1979.
- [90] WHALEN, Th.; SCHOTT, B. Goal-directed approximate reasoning in a fuzzy production system. *Approximate reasoning in Expert Systems*, Gupta et al. (eds.), Amsterdam: Elsevier Science Publishers, 1985, p. 505–518.
- [91] ZADEH, LOFTHI. Fuzzy sets. *Information and Control*, v.8, p.338–353, 1965.
- [92] ZADEH, LOFTHI. Fuzzy sets as a basis for a theory of possibility. *Fuzzy Sets and Systems*, v.1, p.3–28, 1978.
- [93] ZIMMERMANN, HANS J. *Fuzzy Sets, Decision Making, and Experts Systems*. Boston: Kluwer Academic Publishers, 1991.