

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
PÓS-GRADUAÇÃO EM ENGENHARIA E GESTÃO DO
CONHECIMENTO**

Juliano Tonizetti Brignoli

**UM MODELO PARA SUPORTE AO RACIOCÍNIO DIAGNÓSTICO
DIANTE DA DINÂMICA DO CONHECIMENTO SOBRE
INCERTEZAS**

Tese submetida ao Programa de Pós-Graduação em Engenharia e Gestão do Conhecimento da Universidade Federal de Santa Catarina para a obtenção do grau de Doutor em Engenharia e Gestão do Conhecimento.

Orientador: Prof. Denilson Sell, Dr.

Co-orientador: Prof. José L. Todesco, Dr.

Florianópolis
2013

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Brignoli, Juliano Tonizetti

Um modelo para suporte ao raciocínio diagnóstico diante da dinâmica do conhecimento sobre incertezas / Juliano Tonizetti Brignoli ; orientador, Denilson Sell ; co-orientador, José Leomar Todesco. - Florianópolis, SC, 2013. 260 p.

Tese (doutorado) - Universidade Federal de Santa Catarina, Centro Tecnológico. Programa de Pós-Graduação em Engenharia e Gestão do Conhecimento.

Inclui referências

1. Engenharia e Gestão do Conhecimento. 2. Redes Fuzzy-Bayesianas. 3. Conhecimento sobre Incertezas. 4. Raciocínio Clínico. 5. Superposição Conceitual. I. Sell, Denilson. II. Todesco, José Leomar. III. Universidade Federal de Santa Catarina. Programa de Pós-Graduação em Engenharia e Gestão do Conhecimento. IV. Título.

Dedico esta tese à minha mãe Maria Teresinha Brignoli (in memoriam), pelos seus ensinamentos e exemplos de vida. Sua dolorosa perda durante a caminhada neste projeto transformou-se em motivação, encorajada pelas palavras e lições de vida que ela deixou.

AGRADECIMENTOS

Agradeço a Deus, pela vida, pela força e coragem a mim concedidas e que oportunizou alcançar mais este objetivo.

À minha família, minha dedicada esposa e conselheira Ivonete, aos meus amados filhos Fernando e Franciele, por toda a compreensão e as palavras positivas que trouxeram a motivação necessária para a realização deste trabalho.

Ao meu pai Valmor e minha mãe Maria Teresinha (*in memoriam*) por todo o carinho e dedicação em prol da formação de seus filhos. Também, ao meu querido irmão Jorge, por todo o apoio.

À minha querida tia Eliane, pelo carinho e apoio.

Agradeço ao Programa de Pós-Graduação em Engenharia e Gestão do Conhecimento da Universidade Federal de Santa Catarina, seu colegiado, docentes e colaboradores, pela acolhida e suporte dado à realização deste projeto.

Em especial, ao meu orientador e amigo professor Dr. Denilson Sell, pela aceitação das idéias, pelas considerações pontuais que propiciaram a qualidade no desenvolvimento da tese e pelas palavras de motivação.

Ao meu co-orientador professor Dr. José Leomar Todesco por todas as contribuições.

Quero agradecer todo o apoio concedido pela professora e amiga Dra. Silvia Modesto Nassar, pelos aconselhamentos durante os momentos difíceis e por todo o suporte e mediação junto às pessoas envolvidas nesta pesquisa.

Também, agradeço a professora e grande amiga conquistada durante esta pesquisa, Dra. Maria Marlene de Souza Pires, por sua dedicação como médica especialista e pesquisadora que propiciou o acesso ao cenário de aplicação desta tese.

Agradeço aos colegas de trabalho do Instituto Federal Catarinense, em especial, aos docentes do curso de Ciência da Computação, por todo o apoio concedido.

A todos que direta ou indiretamente contribuíram de alguma forma.

Aquilo que os homens de fato querem não é o conhecimento, mas a certeza.

(Bertrand Russell)

RESUMO

A Engenharia do Conhecimento recorre a abordagens transdisciplinares objetivando oferecer soluções às demandas sociais, destacando-se, artefatos para suporte à decisão. A tomada de decisão humana pode ser de magnitude tão complexa que a atividade intensiva em conhecimento realizada pelo especialista demande assistência proveniente de modelos elaborados por uma visão sistêmica do engenheiro do conhecimento no espaço da solução. O problema desta pesquisa emerge da atividade do especialista médico em Classificação de Risco Metabólico em crianças e adolescentes. As variáveis deste cenário e o processo de classificação apresentam incertezas, manifestadas por causalidade e imprecisão. Redes Bayesianas são empregadas no suporte a classificação cujas variáveis que representam o conhecimento são de natureza probabilística. Contudo, o método bayesiano clássico, diante do fator imprecisão, pode convergir para resultados não qualificados em conformidade àqueles obtidos pelo raciocínio clínico. Por outro lado, Redes Fuzzy-Bayesianas aprimoraram o modelo clássico para suportar inferência sobre conceitos ambíguos. Esta pesquisa contribuiu com o desenvolvimento de um modelo de inferência fuzzy-bayesiano para variáveis não-dicotômicas oferecendo suporte ao raciocínio médico num cenário complexo cuja dinâmica da imprecisão é caracterizada por um tipo de superposição conceitual. Essencialmente dispõe de formalismo matemático modificando a equação do Teorema de Bayes, introduzindo qualificadores difusos para lidar com a imprecisão. Para verificar o modelo utilizou-se de simulações aplicadas sobre dados reais de prontuários. Os resultados obtidos mostraram-se convergentes com a interpretação do especialista e a característica notável foi à qualidade destes resultados nos intervalos próximos aos pontos de corte utilizados pelos especialistas e reproduzidos pelo método bayesiano clássico, problema este que não releva a imprecisão. O modelo distribuiu as probabilidades das hipóteses diagnósticas acompanhando a dinâmica inerente a imprecisão das evidências. Este efeito mostra que um paciente, mesmo que de modo gradual, pode estar evoluindo para um cenário de risco metabólico. O modelo é propenso de ser acoplado a metodologias da Engenharia do Conhecimento e sua implementação pode gerar uma ferramenta aliada à prática do diagnóstico clínico.

Palavras-Chave: Redes Fuzzy-Bayesianas, Lógica Fuzzy, Inferência, Ontologias, Diagnóstico Médico, Probabilidade, Incerteza, Imprecisão, Superposição.

ABSTRACT

The Knowledge Engineering uses transdisciplinary approaches aiming to provide solutions to social demands, especially, artifacts for decision support. The human decision making can be so complex that the magnitude knowledge intensive activity undertaken by specialist demande assistance from models developed by a systemic view of the knowledge engineer in the solution space. The problem of this research emerges from the activity of the specialist physician in Metabolic Risk Rating in children and adolescents. The variables of this scenario and the classification process is uncertain, expressed by causality and imprecision. Bayesian networks are employed to support the classification whose variables representing knowledge are probabilistic in nature. However, the classical Bayesian method, given the uncertainty factor can converge to results unskilled in accordance to those obtained by clinical reasoning. On the other hand, improved Bayesian Networks Fuzzy-classical model to support inference about ambiguous concepts. This research contributed to the development of a fuzzy-Bayesian inference for non-dichotomous variables supporting the medical reasoning in a complex scenario whose dynamics of vagueness is characterized by a kind of conceptual overlay. Essentially offers mathematical formalism modifying the equation of Bayes Theorem, introducing fuzzy qualifiers to deal with imprecision. To verify the model we used simulations applied to real data from medical records. The results obtained were convergent with interpretation specialist and notable feature was the quality of these results in the ranges near the cutoff points used by experts and reproduced by classical Bayesian method, a problem that does not excuse the inaccuracy. The distributed model the odds of diagnostic hypotheses tracking the dynamics inherent imprecision of the evidence. This effect shows that a patient, even if gradually, may be evolving into a scenario of metabolic risk. The model is likely to be coupled to the Knowledge Engineering methodologies and their implementation can generate a tool coupled with the practice of clinical diagnosis.

Keywords: Fuzzy-Bayesian Networks, Fuzzy Logic, Inference, Ontology, Medical Diagnosis, Probability, Uncertainty, Imprecision, Superposition.

LISTA DE FIGURAS

Figura 1 – Componentes de um Sistema de Informação	37
Figura 2 – Associação da pesquisa a Metodologia <i>CommonKADS</i>	53
Figura 3 – Noções associadas ao conhecimento	60
Figura 4 – Origens do conhecimento.....	61
Figura 5 – Tipos de conhecimento.....	62
Figura 6 – Elementos da sugestão de aderência da pesquisa	64
Figura 7 - Modelos da Metodologia <i>CommonKADS</i>	70
Figura 8 – Relações entre classes em uma ontologia médica	73
Figura 9 – Representação da metodologia <i>METHONTOLOGY</i>	74
Figura 10 – Possível mapeamento de uma Ontologia para uma <i>RFB</i>	75
Figura 11 – Exemplo de classificação de natureza completa e discreta.....	82
Figura 12 – Exemplo de classificação de natureza subjetiva.....	82
Figura 13 – Sobreposição conceitual pela imprecisão.....	83
Figura 14 – Grafo de representação do problema do Alarme	93
Figura 15 – Rede Bayesiana do problema do Alarme no <i>Shell Netica Norsys</i>	95
Figura 16 – Simulação de inferência – problema do Alarme	96
Figura 17 – Rede Bayesiana para Diagnóstico de Risco Metabólico	98
Figura 18 – Sistema Fuzzy Genérico.....	101
Figura 19 – Exemplificação: conjuntos clássicos e conjuntos fuzzy (cores)	104
Figura 20 – Núcleo, suporte e <i>boundaries</i> de um conjunto fuzzy	107
Figura 21 – Representação da variável <i>PIMC</i> na forma fuzzy com funções não-lineares.....	108
Figura 22 – Processo de <i>fuzzificação</i> sobre a variável <i>PIMC</i>	110
Figura 23 – Diagrama para uma Rede Bayesiana Híbrida.....	113
Figura 24 – Diagrama para uma Rede Bayesiana Híbrida destacando as variáveis contínuas.....	114
Figura 25 – Números de trabalhos publicados por ano ao conjunto de 40 documentos	131
Figura 26 – Volume de trabalhos publicados por ano ao conjunto de 40 documentos – Base Springer	132

Figura 27 – Autores mais citados do conjunto de 40 artigos selecionados	133
Figura 28 – Perspectiva de qualificação do conhecimento incerto	141
Figura 29 – Grafo da representação genérica de uma Rede Bayesiana com estrutura Naive Bayes	144
Figura 30 – Distribuição das probabilidades da saída H após a propagação	146
Figura 31 – Distribuição dos estados fuzzy de uma evidência imprecisa	149
Figura 32 – Superposição de estados difusos de uma evidência imprecisa	151
Figura 33 – Fluxograma da atribuição CRISP ou Fuzzy sobre as variáveis de entrada	157
Figura 34 – Parte Qualitativa da Rede Bayesiana – estrutura hierárquica	159
Figura 35 – Rede Bayesiana para Risco Metabólico – estrutura Naive Bayes	160
Figura 36 – Confirmação PIMC=Magreza	161
Figura 37 – Confirmação PIMC=Magreza e PCA=Adequada	162
Figura 38 – Confirmação PIMC=SobrePeso	163
Figura 39 – Confirmação PIMC=Obeso	163
Figura 40 – Confirmação PIMC=ObesoGrave	164
Figura 41 – Funções de pertinência para uma Superposição de dois estados em PIMC	165
Figura 42 – Parametrização da variável linguística PIMC	165
Figura 43 – Distribuição de Probabilidades para PIMC pela Rede Fuzzy-Bayesiana	167
Figura 44 – Distribuição de Probabilidades para PIMC pela Rede Clássica	168
Figura 45 – Distribuição de Probabilidades para PIMC e PCA pela Rede Fuzzy-Bayesiana	169
Figura 46 – Distribuição de Probabilidades para PIMC e PCA pela Rede Clássica	170
Figura 47 – Distribuição de Probabilidades para PIMC em estados Superpostos	171
Figura 48 – Distribuição de Probabilidades para PIMC em estados Superpostos – inferência clássica	172
Figura 49 – Distribuição de Probabilidades fuzzy-bayesianas para AFS	173

Figura 50 – Distribuição de Probabilidades para AFS na forma clássica.....	174
Figura 51 – Perspectiva da comparação de resultados da RB, RFB e do raciocínio clínico	175
Figura 52 – Gráfico das classificações obtidas pela Rede Bayesiana Clássica sobre o primeiro conjunto de dados	181
Figura 53 – Gráfico das classificações obtidas pelo Modelo Fuzzy-Bayesiano sobre o primeiro conjunto de dados	182
Figura 54 – Gráfico das classificações obtidas pelo Modelo Fuzzy-Bayesiano sobre o primeiro conjunto de dados	183
Figura 55 – Gráfico das classificações obtidas pela Rede Bayesiana Clássica sobre o segundo conjunto.....	190
Figura 56 – Gráfico das classificações obtidas pelo Modelo Fuzzy-Bayesiano sobre o segundo conjunto de dados.....	191
Figura 57 – Gráfico das classificações obtidas pelo Raciocínio Clínico sobre o segundo conjunto de dados.....	192

LISTA DE QUADROS

Quadro 1 – Discussão dos resultados da etapa de revisão abrangente.....	124
Quadro 2 - Organização de strings e resultados da busca primária.....	129
Quadro 3 – Identificação das características observadas na Revisão Sistemática	134
Quadro 4 – Elementos constituintes da especificação do modelo matemático – qualificadores fuzzy	150

LISTA DE TABELAS

Tabela 1 - Trabalhadores que criam o conhecimento	76
Tabela 2 - <i>CPT</i> da variável Alarme	94
Tabela 3 - <i>CPTs</i> das variáveis <i>JoãoAvisa</i> e <i>MariaAvisa</i>	94
Tabela 4 - Estrutura de um vetor de Hipóteses Diagnósticas e suas probabilidades.....	145
Tabela 5 - Estrutura geral de uma <i>CPT</i>	145
Tabela 6 – Classificações: Rede Bayesiana Clássica - 1°. Conjunto de Dados.....	177
Tabela 7 – Classificações: Modelo Fuzzy-Bayesiano - 1°. Conjunto de Dados.....	178
Tabela 8 – Classificações: Raciocínio Clínico – 1°. Conjunto de Dados	179
Tabela 9 – Classificações: Rede Bayesiana Clássica - 2°. Conjunto de Dados.....	187
Tabela 10 – Classificações: Modelo Fuzzy-Bayesiano - 2°. Conjunto de Dados.....	188
Tabela 11 – Classificações: Raciocínio Clínico - 2°. Conjunto de Dados	189
Tabela 12 – Resumo da discussão de resultados – 1°. Conjunto de dados	200
Tabela 13 – Resumo da discussão de resultados – 2°. Conjunto de dados	201

LISTA DE SIGLAS E ABREVIATURAS

AFS – Atividade Física Semanal

BLP – Bayesian Logic Programming

CA – Circunferência Abdominal

CIS - Clinical Information System

CPGs - Clinical Practice Guidelines

CPT – Conditional Probabilities Table

DAG - Grafo Dirigido Acíclico

DCNT – Doenças Crônicas não Transmissíveis

DCV – Doenças Cardiovasculares

DL – Description Logic

DM2 - Diabetes tipo 2

DXPlain - Sistema para diagnóstico em medicina interna

FBN – Fuzzy Bayesian Network

GLIF - Padrão baseado na Web Semântica para representar *guidelines* clínicos

HAS - Hipertensão Arterial Sistêmica

HNB - Rede Bayesiana Híbrida genérica

IA – Inteligência Artificial

ICL - Lógica de Escolha Independente

IMC – Índice de Massa Corpórea

IPFP - Iterative Proportional Fitting Procedure

KBS – Knowledge-based System

KDD - Knowledge Data Discovery

KEMM - Metodologia de Engenharia do Conhecimento

LDL – Tipo de Colesterol

MCDM - Multi-criteria decision making

MEBN - Multi-Entity Bayesian Networks

Mfrags – Coleção de fragmentos de uma Rede Bayesiana Multi-Entidade

OMS – Organização Mundial da Saúde

ontoKEM – Ferramenta orientada a projetos de ontologias

OWL – Ontology Web Language

PCA - Perfil de Circunferência Abdominal

PIMC – Perfil de Índice de Massa Corpórea

PR-OWL – Probabilistic Ontology Web Language

QMR - Quick Medical reference System

RBC – Raciocínio Baseado em Casos

RDF - Resource Description Framework

RFB – Rede Fuzzy-Bayesiana

SAD - Sistema de Apoio a Decisão

SBC – Sistema Baseado em Conhecimento

SAGE - Standards-based Sharable Active Guideline Environment

SD – IPFP – Método derivado de IPFP

SODOnt – Ontologia para definição de um vocabulário comum para médicos

TraumID – Sistema de apoio ao diagnóstico de trauma no tórax

UMP-ST - Modeling Process for Semantic Technologies

VLDL – Tipo de Colesterol

SUMÁRIO

1	INTRODUÇÃO.....	37
1.1	Apresentação	37
1.2	Descrição do problema	41
1.3	Pergunta de pesquisa	45
1.4	Objetivos	45
1.4.1	Objetivo geral	45
1.4.2	Objetivos específicos	45
1.5	Justificativa.....	46
1.5.1	Aspectos gerais	46
1.5.2	Relevância	48
1.5.3	Ineditismo	54
1.6	Metodologia	55
1.6.1	Tipificação da pesquisa e fatores epistemológicos ..	55
1.6.2	Aderência em contribuição a Engenharia do Conhecimento	60
1.6.3	Teorias, técnicas e ferramentas	65
1.7	Organização e escopo	66
1.7.1	Estruturação	66
1.7.2	Delimitações	67
2	REVISÃO DE LITERATURA	69
2.1	Engenharia do Conhecimento	69
2.1.1	Fatores paradigmáticos	69
2.1.2	Ferramentas de suporte ao processo de diagnose médica	71
2.1.3	Suporte metodológico das ontologias	73
2.2	O especialista e a atividade intensiva em conhecimento	76
2.3	O cenário e a atividade clínica na diagnose do Risco Metabólico	77
2.4	Representação do conhecimento sobre incertezas.....	81
2.5	Redes Bayesianas	85
2.5.1	O conhecimento representado por probabilidades... 85	
2.5.2	Definições formais de probabilidade	86
2.5.2.1	Axiomas e Propriedades.....	87
2.5.2.2	Probabilidade Condicional	87
2.5.3	O raciocínio bayesiano	88
2.5.4	Redes Bayesianas e o processo de classificação.....	90

2.5.4.1	Aspectos Estruturais das Redes Bayesianas	90
2.5.4.2	Processo de Distribuição de Probabilidade Conjunta	95
2.5.5	Limitações das Redes Bayesianas diante da imprecisão.....	97
2.6	Lógica Fuzzy e o raciocínio heurístico.....	99
2.6.1	Probabilidade <i>versus</i> Possibilidade.....	101
2.6.2	Conjuntos clássicos e Conjuntos fuzzy.....	103
2.6.3	Funções de pertinência fuzzy.....	106
2.6.4	Conversão Crisp-Fuzzy	109
2.7	Redes Fuzzy-Bayesianas	110
2.7.1	Probabilidade sobre eventos fuzzy	111
2.7.2	Redes Bayesianas Híbridas.....	113
2.7.3	Um modelo de Rede Fuzzy-Bayesiana com variáveis dicotômicas	115
2.8	Princípio da Superposição de Estados	119
2.9	Estado-da-Arte do conhecimento sobre incertezas.....	121
2.9.1	Análise exploratória abrangente	122
2.9.2	Pesquisa Sistemática.....	127
2.9.2.1	Motivação.....	127
2.9.2.2	Seleção de artigos.....	128
2.9.2.3	Análise bibliométrica	130
2.9.2.4	Análise da Revisão Sistemática.....	134
3	MODELO DE INFERÊNCIA FUZZY-BAYESIANO	139
3.1	Perspectiva de tratamento do conhecimento incerto	139
3.2	O modelo.....	143
3.2.1	Análise da modelagem sobre imprecisão.....	150
3.2.2	Indução ao raciocinador fuzzy-bayesiano não-dicotômico.....	153
3.3	Insumos do Conhecimento e a Verificação de Resultados	158
3.3.1	Retomando a descrição do domínio.....	158
3.3.2	A Rede Bayesiana com estrutura <i>Naive Bayes</i>	160
3.3.3	A Rede Fuzzy-Bayesiana: influências do fator imprecisão.....	164
3.3.4	Verificação do Modelo aplicado sobre Dados.....	166
3.3.5	Verificação do Modelo mediante a análise do Especialista.....	174

4	CONSIDERAÇÕES FINAIS	195
5	SUGESTÕES PARA FUTUROS TRABALHOS.....	202
	REFERÊNCIAS BIBLIOGRÁFICAS.....	204
	APÊNDICE A - Resultados da busca com escopo abrangente.....	219
	APÊNDICE B - Resultados da busca com escopo abrangente acrescentando o termo “estocástico” ...	221
	APÊNDICE C - Resultados da busca sobre os termos “Ontologias” E “Probabilidade”	223
	APÊNDICE D - Conteúdos para análise da revisão sistemática	225
	APÊNDICE E - Autores mais citados do conjunto de 40 artigos selecionados	246
	APÊNDICE F - Extratos da planilha utilizada para simulações do Modelo de Inferência Fuzzy-Bayesiano: Base de Conhecimento – dados da Rede Bayesiana Clássica	247
	APÊNDICE G - Extratos da planilha utilizada para simulações do Modelo de Inferência Fuzzy-Bayesiano: modelagem da imprecisão – configuração de parâmetros das funções de pertinência fuzzy	248
	APÊNDICE H - Extratos da planilha utilizada para simulações do Modelo de Inferência Fuzzy-Bayesiano: propagação de resultados com a aplicação das fórmulas de inferência.....	249

APÊNDICE I - Extratos da planilha utilizada para simulações do Modelo de Inferência Fuzzy-Bayesiano: dados provenientes do especialista.....	250
ANEXO A - Tabelas com dados probabilísticos para formação da Base de Conhecimento da Rede Bayesiana Clássica.....	252
ANEXO B - Base de dados reais – levantamento e diagnóstico Realizado pelo especialista médico – Conjunto de dados 1.....	255
ANEXO C – Base de dados reais – levantamento e diagnóstico realizado pelo especialista médico – Conjunto de dados 2.....	258

1 INTRODUÇÃO

1.1 Apresentação

Na atual conjuntura do desenvolvimento das ferramentas de suporte à decisão, a Engenharia do Conhecimento vem se consolidando como uma das áreas de maior contribuição para tal propósito. Suas metodologias e ferramentas conceituais são resultantes do aprimoramento de uma forma interdisciplinar que agrega as melhores práticas e bases teóricas oriundas do campo da Filosofia, da Lógica, da Matemática, da Computação, das Ciências Cognitivas, da Gestão, entre outras (SCHMITT *et al.*, 2006).

Para compreender a atual caracterização da Engenharia do Conhecimento é necessário reportar-se a uma visão panorâmica que descreve a evolução das principais categorias de sistemas voltados para suporte a decisão humana que perpassam pela dualidade conceitual *Informação – Conhecimento*.

Logo, objetivando esta compreensão, observa-se a definição dada por Freitas *et al.* (1997, p.77) acerca da definição de Sistemas de Informação. Segundo o autor, estes sistemas “*são mecanismos cuja função é coletar, guardar e distribuir informações para suportar as funções gerenciais e operacionais das organizações*”.

Laudon (1999) apresenta os componentes essenciais de um Sistema de Informação, conforme ilustra a figura 1:

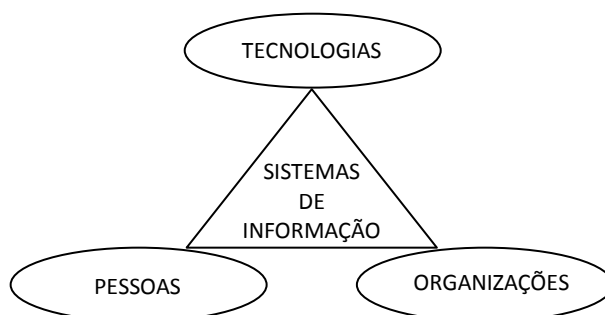


Figura 1 – Componentes de um Sistema de Informação
Fonte: Adaptado de Laudon (1999)

Ao analisar a definição de (Freitas, 1997) em junção com a visão de Laudon (1999) observa-se que um Sistema de Informação atua especificamente na transformação de dados em informação direcionada a algum propósito organizacional dado pela demanda do fluxo da informação e das transações realizadas por pessoas que atuam nos diversificados setores desta organização. Logo, é perceptível que o objetivo de um Sistema de Informação não é o tratamento da informação em um nível semântico, não exigindo assim, qualquer mecanismo mais elaborado que emula algum princípio do comportamento inteligente humano, por exemplo, um processo de inferência.

Contudo, uma categoria mais especializada de Sistema de Informação é aquela denominada de SAD (Sistema de Apoio a Decisão) que, em conformidade com Sauter (1997), surgiu pela necessidade de melhor qualificar um Sistema de Informação destinado ao suporte em processos decisórios. Este tipo de sistema já emprega em sua composição um *banco de conhecimento*, embora projetados, segundo Sauter (1997) para uma situação individual em termos de atendimento a alguma demanda organizacional.

Observa-se que esta categoria de sistema promove a necessidade do aprimoramento e emprego de técnicas especializadas ao tratamento da informação em nível mais semântico emergindo para outra perspectiva – o conhecimento especializado. Sobre esta proposição é oportuno observar as considerações dadas por Turban, McLean e Wetherbe (1996), o qual descreve que um Sistema de Apoio a Decisão oferece suporte às decisões do tipo, semi-estruturadas e não-estruturadas. Para o autor, as decisões semi-estruturadas são aquelas que combinam soluções e procedimentos padrões com base em julgamento individual baseado em experiência enquanto que, as decisões não-estruturadas são baseadas em processos vagos e complexos, cuja intuição humana é frequentemente utilizada.

Esta última afirmativa conduz a visão panorâmica proposta no início desta unidade em apresentar os Sistemas Especialistas como uma categoria que utiliza da informação em termos de insumo mais elaborado semanticamente para gerar o conhecimento apropriado a decisão.

Para Laudon (1999), os Sistemas Especialistas surgiram por volta da década de 1970 com o objetivo de oferecer soluções baseadas na utilização de técnicas de Inteligência Artificial, de modo a substituir o ser humano na resolução de problemas específicos.

Laudon (1999) conceitua: “*A inteligência artificial é o estudo e a criação de máquinas que exibam qualidades semelhantes às humanas, incluindo a capacidade de raciocinar*”.

Shadbolt e Milton (1999) apresentam em sua obra um *background* acerca da evolução da Engenharia do Conhecimento em correlação com o emprego das técnicas de Inteligência Artificial focadas no desenvolvimento de soluções *ad hoc*, tornando-se observável, que os Sistemas Especialistas foram os primeiros artefatos produzidos por aquela forma paradigmática da Engenharia do Conhecimento até então.

Apesar do potencial destas ferramentas e da eficácia de algumas aplicações bem sucedidas como os sistemas, MYCIN (Shortliffe, 1976), DENTRAL (Feigenbaum; Buchanan; Lederberg, 1971) e Prospector (Hart; Duda; Einaudi, 1978), projetos desenvolvidos a partir do paradigma antigo da Engenharia do Conhecimento em consonância com a utilização das ferramentas de Inteligência Artificial, eram desprovidos, conforme retrata Schreiber *et al.* (2002), de considerações mais detalhadas acerca do domínio do problema e não releva todo o contexto que o circunda. Esta observação converge com Shadbolt e Milton (1999), o qual descreve o fato de que nos anos mais recentes, engenheiros do conhecimento procuraram adotar princípios, métodos e técnicas de Engenharia do Conhecimento numa perspectiva mais real e inserida no contexto da Gestão do Conhecimento.

A Engenharia do Conhecimento, em seu novo paradigma, passa a levar em consideração, de uma forma sistemática, todo um contexto ambiental, comportamental, tecnológico e, em especial, envolvendo todo e qualquer aspecto humano de participação à elaboração de projetos destinados a construção dos denominados Sistemas de Conhecimento (GEENEN, 2004).

Conforme retratado em Borlawsky, Friedman e Lussier (2006), uma das áreas que tem-se oportunizado da disponibilização das ferramentas da Engenharia do Conhecimento é a “medicina baseada em evidências” no que refere-se aos processos de orientação e tomada de decisão em atividades de diagnose. Sobre este aspecto, soluções foram desenvolvidas por meio de Sistemas de Raciocínio Baseado em Casos, Redes Semânticas de representação de conceitos, Sistemas Especialistas, entre outros.

A heterogeneidade dos resultados de diagnósticos médicos resultante do grau de complexidade do conhecimento acerca de um domínio específico também é vista como um problema que pode ser minimizado por ferramentas da Engenharia do Conhecimento (PIRES, 2007).

O aprimoramento da qualidade deste conhecimento pode ser alcançado a partir do compartilhamento e da comunicação entre informações esparsas em sistemas de registros de prontuários, sistemas de informação médica e do próprio conhecimento tácito dos especialistas. Em conformidade com Gruber (1993), as ontologias são formas de

representação de conhecimento com a vantagem de prover esta capacidade de compartilhamento, de disponibilização e comunicação entre agentes que atuam no domínio em discussão.

Um dos fatores desafiadores nos processos do diagnóstico médico é a existência de graus de incerteza no raciocínio frente ao quadro clínico do paciente baseado na coleta de dados da anamnese, dos sinais e sintomas referentes ao exame físico, dos exames laboratoriais bioquímicos e de imagem, dos pontos de corte dos dados coletados, dos consensos e diretrizes. Todo esse processo é norteado pelo conhecimento médico construído por meio de três vertentes: conhecimento formal ou científico, o conhecimento experiencial e o conhecimento baseado em evidências. As incertezas intrínsecas nas relações conceituais e nas bases de evidências formadas a partir de dados coletados que irão constituir o portfólio do paciente resultam às vezes, em estresse na tomada de decisão (PIRES, 2012).

O aforismo de William Osler, “Medicina é a ciência da incerteza e a arte da probabilidade” expressa a necessidade de pesquisas, unindo a medicina à engenharia do conhecimento (PHUA e Tan, 2013; TUOTO, 2011).

Conforme observado na obra de Kasabov (1998), o tratamento do conhecimento sobre incertezas tem-se desenvolvido de uma forma bastante acentuada nos últimos anos. As abordagens estocásticas na modelagem de Sistemas de Conhecimento trouxeram significativos avanços para a eficácia na orientação e tomada de decisão, não somente na área clínica, como também, em outras áreas do conhecimento humano que recorrem ao propósito similar.

Soluções para processos de classificação sobre incertezas recorrem às técnicas probabilísticas, como é o caso das Redes de Probabilidades Bayesianas e também às possibilísticas, especialmente observadas a Lógica Fuzzy e teorias correlatas aplicáveis aos problemas de processamento do conhecimento sobre imprecisão (KASABOV, 1998).

Nos últimos dez anos alguns trabalhos de pesquisa sugeriram o uso de Ontologias na representação de conhecimento incerto e, uma parcela destes, contribuiu com modelos baseados em Probabilidade Ding (2005) e outra, com modelos baseados em Possibilidade, conforme elucidado em Borges *et al.* (2010), contudo, cada qual numa concepção unilateral em termos de suas soluções.

A complexidade em domínios de conhecimento sobre cenários de incerteza exige do Engenheiro do Conhecimento a utilização de técnicas e ferramentas diversificadas na concepção de modelos de solução. Em Williams, Weber e Hawkins (2009) pode-se compreender que a mensuração

de incertezas exige de certo modo conjunturas híbridas para prover soluções eficazes na modelagem de problemas com aspectos complexos.

A interpretação do fenômeno da incerteza não é uma propriedade inerente apenas do campo da matemática estocástica, da estatística, das técnicas bayesianas e difusas, em lidar com variáveis desta natureza. Estudos no campo da Física Quântica fornecem argumentações e expõem de forma metafórica alguns elementos pontuais na compreensão do fenômeno da incerteza. A exploração do denominado *Princípio da Superposição de Estados* (PESSOA, 2003) pode sugerir uma inspiração à estratégia de composição da solução para o problema do raciocínio sobre incertezas.

Morin (2005) discorre sobre a incerteza e a complexidade de modo associativo. Para o autor, a incerteza é uma das componentes daquilo que ele o define como “uma pesada carga semântica” que tenta provar a legitimidade da complexidade por esta não ter uma nobre herança filosófica, científica ou epistemológica.

A afirmativa de Morin (2005) reforça, de certo modo, a coerência entre a investigação acerca do problema da incerteza e a necessidade da empregabilidade do pensamento complexo que será adotado como pressuposto metodológico na exploração dos elementos desta pesquisa.

Na sequência serão apresentados os detalhes relacionados à problemática da pesquisa e o propósito da investigação.

1.2 Descrição do problema

No âmbito das teorias e ferramentas que descrevem soluções para a problemática da representação e do tratamento realizado sobre o conhecimento incerto destacam-se as consolidadas Redes Bayesianas de Probabilidades ou Redes de Crença. De acordo com Pearl (1988) este recurso oriundo das técnicas de Inteligência Artificial oferece uma maneira estruturada de Representação do Conhecimento sobre relações de natureza incerta, dada sobre a forma de variáveis probabilísticas caracterizadas por estados discretos associados aos conceitos do domínio.

O método de inferência ou raciocínio utilizado pelas Redes Bayesianas é o cálculo de probabilidades condicionais formulados pela aplicação do denominado Teorema de Bayes (PEARL, 1988).

Apesar do vasto campo de sua aplicabilidade, a inferência bayesiana não releva o fato da existência de imprecisão nas variáveis que expressam o domínio representado, poder influenciar na qualidade de seus resultados e, conseqüentemente, no processo de suporte a tomada de decisão. Esta

proposição é plausível se observado o que afirma Ross (1995) sobre o problema ou limitação do método de inferência bayesiano clássico diante do que ele descreve ser: eventos vagos e ambíguos.

Sabe-se que as incertezas podem se manifestar de diversas maneiras além da causalidade, que é a forma interpretada pelo raciocínio bayesiano. Observado em (Mamdani, 1981), a imprecisão é outra forma de manifestação de incerteza presente nas relações conceituais subjetivas, de natureza incompleta ou de informação sobreposta.

A Lógica Fuzzy dispõe de um conjunto de técnicas baseadas em formalismo matemático apropriado para lidar com modelagem de sistemas cujo fator incerteza se manifesta nas variáveis do domínio sob a forma de imprecisão e onde o conhecimento é denotado pelo raciocínio aproximado ou heurístico (ZADEH, 1994) e (ROSS, 1995).

De acordo com as conclusões obtidas no trabalho de (Mayer, 2012), observou-se que o fator limitante comprometedor da qualidade dos resultados obtidos por processos de inferência em Redes Bayesianas e que orientam a tomada de decisão de especialistas humanos, a exemplo, no contexto da especialidade clínica em tarefas de diagnose, é a classificação equivocada nos limítrofes dos intervalos que descrevem os estados que representam conceitos do domínio modelado. Mudanças abruptas nos valores de probabilidades dos estados associados ao conhecimento da Rede Bayesiana resultam em classificações que tendem a não convergir para uma realidade, indicando certas discrepâncias se correlacionadas ao conhecimento ou experiência vivida pelo próprio especialista humano.

Observado o que descreve Ross (1995) acerca da limitação da inferência bayesiana clássica e de sua introdução a proposição do *método de decisão fuzzy-bayesiano* é pertinente qualificar que o raciocínio bayesiano seja de caráter bivalente e limitado em sua conjectura matemática de raciocinar sobre variáveis que denotam imprecisão, caracterizada em especial pela ambiguidade dos termos que descrevem os subintervalos destas variáveis, ou ainda, limitado no aspecto de lidar com a existência daquilo que será identificado e explorado como uma *sobreposição ou superposição conceitual*.

Mayer (2012) analisou o desempenho de uma Rede Bayesiana em sua pesquisa no campo da medicina pediátrica e mostrou que a rede teve dificuldades na classificação de risco metabólico não reconhecendo indicadores diagnósticos os quais seriam percebidos pelo especialista humano. Conforme observado em suas conclusões, a tendência do raciocínio bayesiano em alguns casos era diagnosticar de modo não qualificado a uma realidade da prática clínica. Assim sendo, Mayer (2012)

sugere um refinamento das probabilidades ou uma associação do modelo bayesiano com outras técnicas.

Como já mencionado anteriormente, alguns trabalhos, tais como mostram Borges *et al.* (2010) e Ding (2005) já desenvolveram soluções para as Ontologias que descrevem relações conceituais de um domínio vinculado a incertezas. Algumas soluções focaram em abordagens que poderíamos denotar como “de visão unilateral”, ou seja, ou uma Ontologia é elaborada sobre os pressupostos da Teoria da Probabilidade, como é o caso das pesquisas que resultaram em linguagens de representação de ontologias probabilísticas (*PR-OWL*, por exemplo), ou trabalha na concepção da Teoria da Possibilidade e suas propostas metodológicas como a Lógica Fuzzy.

Outros trabalhos, como analisado em Pan (1999) propuseram que as Redes Bayesianas pudessem representar não somente variáveis discretas, mas também, contínuas. As Redes Bayesianas Híbridas convergiram para o surgimento das denominadas Redes Fuzzy-Bayesianas. Neste contexto, algumas contribuições científicas disponibilizaram modelos matemáticos para permitir que estas estruturas de representação de conhecimento pudessem inferir sobre variáveis aleatórias com ruídos de imprecisão.

É notório que em certos domínios a complexidade na representação do conhecimento dada pela natureza das variáveis envolvidas na modelagem e pela própria dinâmica intrínseca nas relações exige abordagens mais elaboradas para o tratamento de incertezas representadas por Redes Fuzzy-Bayesianas.

Esta última proposição converge com Araújo (2012) quando este analisa a necessidade do emprego de métodos computacionais mistos para atender a demanda do avanço da complexidade dos conjuntos difusos conforme o rigor no processo de investigação. O autor discorre sobre esta possibilidade de concepção de abordagens híbridas envolvendo o que refere-se como a Estatística Bayesiana e os Conjuntos Difusos no contexto da metodologia de pesquisa em Educação Matemática.

Soluções mais próximas em fornecer suporte para aplicações com modelos diretamente focados às especificidades de uma demanda e disponíveis como forma de hibridismo empregando Lógica Fuzzy no suporte a inferência bayesiana apresentam tratamento dicotômico às variáveis associadas aos estados de conceitos sobrepostos.

Brignoli (2001) e Tibiriçá (2005) desenvolveram esta abordagem dicotômica em um modelo de raciocínio híbrido difuso-probabilístico. Este modelo apresentou-se eficaz diante da utilização de variáveis probabilísticas com somente dois estados discretos em sua composição conceitual, o que caracteriza uma forma dicotômica. A partir de então

utilizou-se uma forma de princípio da complementaridade entre a difusão ou transição entre os estados – *presença e ausência*. Os parâmetros do modelo não o permitem inferir sobre variáveis com múltiplos estados contínuos e dinâmicos.

É plausível analisar se esta visão dicotômica de representar as variáveis do domínio pode incorrer em resultados menos qualificados quando a dinâmica destas variáveis é consideravelmente acentuada.

Para instanciar esta suposição acerca da dicotomia na análise de estados sobrepostos, o que se pode afirmar, por exemplo, quando uma decisão baseada em processo classificatório bayesiano sugere um determinado grau de *Risco Metabólico* para uma criança ou adolescente que esteja com um *Índice de Massa Corpórea* classificado dentro de um intervalo de subjetividade que perpassa pelos conceitos – *Sobre Peso, Obeso e Obeso Grave?*

É notório que estes conceitos como subconjuntos de uma variável linguística do tipo – *Perfil do Índice de Massa Corpórea*, que resultam da aferição de medidas em escalas numéricas, denotam de forma natural a existência de subjetividade e principalmente de sobreposição conceitual, interferindo diretamente num processo semântico de classificação.

Uma Rede Bayesiana, em sua forma clássica, com inferência probabilística sobre este tipo de incerteza manifestada por imprecisão não pode fornecer classificações em forma de distribuição de probabilidades de forma eficaz. Ao invés disso, o raciocinador infere de modo a não perceber discrepâncias causadas pela falta de percepção acerca da gradação ou das transições graduais entre os estados destas variáveis linguísticas.

É observável que outros trabalhos focaram sua abordagem no interesse de descrever exaustivamente o formalismo matemático que propicia a formação de uma Teoria das Redes Fuzzy-Bayesianas, reportando-se aos lemas tradicionais da Teoria da Probabilidade, redefinindo proposições segundo os seus entendimentos acerca da formação de funções de densidade de probabilidade sobre eventos fuzzy. São desprovidos do interesse imediato em solucionar problemas num contexto mais realista em torno da interpretação semântica sobre o conhecimento inferido em incertezas.

Em síntese à descrição desta unidade levanta-se a problemática da pesquisa: ineficácia das Redes Bayesianas Clássicas em processos classificatórios nos estados limítrofes que descrevem as variáveis em domínios com acentuada dinâmica em torno do fator imprecisão dada pela superposição conceitual.

1.3 Pergunta de pesquisa

Exposta a problemática acerca da representação do conhecimento por meio das Redes Bayesianas Clássicas, cujo cenário de aplicação apresenta variáveis munidas de imprecisão e denotadas por uma dinâmica caracterizada por superposição conceitual em seus estados, formaliza-se a seguinte pergunta de pesquisa que norteará a busca pelas argumentações teóricas e o desenvolvimento do modelo que se propõe:

Qual modelo de inferência para Redes Fuzzy-Bayesianas pode ser desenvolvido e aplicado no diagnóstico clínico voltado à Classificação de Risco Metabólico de crianças e adolescentes?

1.4 Objetivos

1.4.1 Objetivo geral

Elaborar um modelo de suporte ao raciocínio sobre incertezas em atividade intensiva de conhecimento proveniente de um cenário complexo e dinâmico em diagnose clínica, voltado à classificação de Risco Metabólico em crianças e adolescentes.

1.4.2 Objetivos específicos

- Averiguar o domínio e o cenário da atividade clínica de diagnose em classificação de Risco Metabólico em crianças e adolescentes identificando as limitações das Redes Bayesianas Clássicas neste processo;
- Identificar os elementos essenciais para a concepção do modelo de inferência ao processo de classificação de Risco Metabólico exercido pelo especialista humano;
- Analisar as características dos resultados da classificação bayesiana diante da imprecisão inerente às variáveis do domínio;
- Identificar as características dos resultados da distribuição de probabilidades em Redes Fuzzy-Bayesianas com variáveis

modeladas na forma dicotômica e suas limitações para lidar com variáveis de estados superpostos;

- Formular matematicamente o novo modelo de inferência para Redes Fuzzy-Bayesianas com variáveis não-dicotômicas de estados superpostos;
- Verificar o modelo mediante a simulação com dados provenientes de planilhas elaboradas a partir de registros de prontuários e com a interpretação realizada por especialista médico.

1.5 Justificativa

1.5.1 Aspectos gerais

Inicialmente, torna-se propício expor a argumentação que responda ao questionamento mais elementar observados a problemática e o objetivo estabelecido nesta pesquisa:

Por que recorrer às teorias das Redes Bayesianas, da Lógica Fuzzy e das Redes Fuzzy-Bayesianas, vislumbrando solução à problemática com esforços a gerar um modelo a partir de uma conjuntura híbrida para lidar com o conhecimento sobre incerteza?

O fato de recorrer a esta abordagem está associado à natureza do conhecimento caracterizado no cenário da problemática. O fenômeno da incerteza é manifestado, em primeiro plano, pela existência de variáveis aleatórias, ou seja, o modelo de representação do conhecimento para classificar Risco Metabólico é essencialmente probabilístico. Contudo, em segundo plano, observa-se o fator imprecisão que interfere na qualidade semântica da classificação probabilística realizada pelo método de inferência bayesiano. Assim sendo, uma abordagem estocástica mantém-se como solução almejada e para tal, orientando-se pelas proposições de Zadeh (1965), Ross (1995) e Kandel (1986), o emprego de modelagem da imprecisão utilizando funções de pertinências difusas parece ser o caminho mais promissor.

É conhecido o fato de que outras técnicas oriundas do campo da Inteligência Artificial são utilizadas para lidar com informação incerta, tais como, *RBC (Raciocínio Baseado em Casos)*, *RNA (Redes Neurais Artificiais)* e Algoritmos Genéticos (RUSSELL e NORVIG, 1995).

Contudo, esta pesquisa aborda um problema de classificação e busca um modelo de suporte ao processo de inferência. Não se trata de recuperação de informação por graus de similaridade (RBC), também não é um problema essencial de Reconhecimento de Padrão (RNA) e não recorre a critérios de otimização de resultados seguindo uma abordagem evolutiva, embora haja soluções que empreguem estas técnicas, conforme será elucidado posteriormente por alguns trabalhos encontrados na Revisão Sistemática.

A forma convencional de classificação probabilística realizada pelo método de inferência bayesiano empregado tradicionalmente em Sistemas Especialistas, a exemplo, em apoio ao Diagnóstico Médico, retorna resultados que em alguns casos não convergem com as expectativas reais do especialista humano, observação esta que confere às conclusões obtidas por Mayer (2012) em seus experimentos com esta ferramenta. Seu trabalho revelou que, diante da imprecisão, expressa em conceitos subjetivos e sobrepostos nos estados das variáveis probabilísticas o método de inferência bayesiano clássico resultou em alterações abruptas nas classificações, em especial, quando os estados possuem uma transição conceitual muito próxima, a exemplo, quando o raciocínio infere na variável do domínio *PIMC (Perfil de Massa Corpórea)* em seus estados – *SobrePeso, Obeso e ObesoGrave*. Os intervalos limítrofes denotam certo *ruído* de informação que interfere na eficácia da inferência bayesiana, ou seja, semanticamente, não condiz com a realidade.

As considerações acerca da imprecisão empregada em modelos híbridos de inferência fuzzy-bayesiana, numa forma de qualificar o raciocínio probabilístico frente a este tipo de incerteza complexa, conforme sugerido, especificado e aplicado por Brignoli (2001) no caso, com variáveis dicotômicas, também não dispõe de solução ideal quando a dinâmica das variáveis do domínio é significativamente acentuada. O problema da Classificação de Risco Metabólico em crianças e adolescentes possui variáveis que além de imprecisas ou subjetivas, sua especificação é composta por múltiplos estados ou conceitos sobrepostos. O modelo dicotômico não provê capacidade de raciocinar sobre a Superposição de Estados.

Ao referenciar *Superposição de Estados* como uma característica implícita na dinâmica da incerteza observada no contexto do problema da Classificação de Risco Metabólico é propenso, sob uma visão sistêmica, discorrer um paralelo com a afirmativa de Pessoa (2003): “*A visão instrumentalista da Física Quântica não se preocupa em interpretar aquilo que está além das nossas observações, mas realizar previsões conforme medições*”.

Esta proposição é importante para justificar que os fatos “escondidos” pela complexidade da dinâmica da incerteza tornam necessário o desenvolvimento de modelos para suporte ao raciocínio sobre incerteza utilizando-se de uma abordagem mais transgressiva, observado o que contextualiza Nowotny (2010), que possam representar um novo conhecimento que emerge desta dinâmica. Uma vez explicitado este novo conhecimento o especialista pode redefinir seus critérios para tomar novas decisões.

1.5.2 Relevância

Na perspectiva mais abrangente desta pesquisa como contribuição ao incremental teórico e tecnológico à Engenharia do Conhecimento é fundamental salientar a importância da concepção de modelos voltados a atender às demandas associadas ao problema do tratamento do conhecimento sobre incertezas.

O cenário em que a presente pesquisa discorre sobre o problema da representação e do raciocínio sobre conhecimento incerto elucidada de modo enfatizante que uma tomada de decisão realizada por um especialista humano pode ser prejudicada em termos de sua eficácia ou acurácia quando a atividade é intensiva em conhecimento, contudo, desprovida de ferramentas capazes de lidar com a complexidade inerente ao conjunto de variáveis manipuladas pelo especialista na dinâmica em que está imerso.

É plausível uma reflexão quanto à capacidade de retenção de todas as informações por parte do especialista humano em seu aspecto mais cognitivo quando depara-se com uma conjuntura de variáveis e relações acentuadamente dinâmica. Indicadores de decisão podem não se manifestar de uma forma tão explícita possível que o processo se conclui de forma desqualificada frente a uma realidade não observada.

A Engenharia do Conhecimento oferece abordagens voltadas à concepção de soluções para o problema do tratamento do conhecimento sobre incertezas. No entanto, algumas destas soluções são parciais em termos de oferecer uma visão unilateral quanto à característica do tipo de incerteza manifestada no cenário do problema. Esta afirmativa pode ser validada ao se observar as contribuições encontradas nos trabalhos de Borges *et al.* (2010), Ding (2005) e outros que serão detalhados posteriormente como resultados de revisão sistemática.

O conhecimento estocástico pode ser tão complexo que necessite de formas híbridas de concepção de modelos. Um tipo bastante comum de incerteza é aquela manifestada sob a forma de aleatoriedade (NASSAR,

2012) e sua representação pode ser especificada por probabilidades. Contudo, estas probabilidades podem estar associadas às variáveis inerentes a outro tipo de incerteza que a precede – a imprecisão (BRIGNOLI, 2001), a qual pode modificar intensamente o real significado do conhecimento que está sendo considerado na tomada de decisão.

Araújo (2012) investigou os aspectos fundamentais e epistemológicos que sugerem a agregação de métodos quantitativos aos métodos qualitativos na pesquisa em Educação Matemática. O autor discute sobre os conceitos de variabilidade e imprecisão e deseja compreender a racionalidade desta agregação para compreender não somente o aspecto substantivo do método bayesiano, mas também o seu aspecto metodológico. Neste contexto, Araújo (2012) recorre a Viertl (2011) que descreve a necessidade do emprego do *Método Estatístico Bayesiano com Dados Difusos*.

Este trabalho explora a abordagem da agregação ou hibridismo das técnicas de tratamento do conhecimento sobre a incerteza o qual, segundo Araújo (2012), tem sustentação epistemológica discorrida pela filosofia de Popper¹. As Redes Fuzzy-Bayesianas estão inseridas neste contexto.

Uma observação acerca das limitações individuais da Lógica Fuzzy e do mecanismo de inferência bayesiano no tratamento de incertezas é descrito por Yang, Bonsall e Wang (2008). No artigo, os autores argumentam a necessidade de pesquisa para a combinação: *Fuzzy-Bayesian* e afirmam:

Vale ressaltar que o conceito de Fuzzy-Bayesiana pode ser explicado em diferentes sentidos, e expresso em vários formatos para resolver diversos problemas de investigação e interesses (YANG, BONSTALL e WANG, 2008, p.518).

Esta afirmativa sustenta diretamente o objetivo principal desta pesquisa, por tratar essencialmente de uma contribuição para este “*Formato*”, referenciado por Yang, Bonsall e Wang (2008) representado por modelagem matemática almejando o hibridismo “*Fuzzy-Bayesiano*”.

Devido ao fato das Redes Bayesianas Clássicas não serem apropriadas para classificações em domínios com variáveis aleatórias associadas à imprecisão, algumas pesquisas propuseram outras abordagens

¹ Karl Raimund Popper. Filosofia do *Racionalismo Crítico*. Livro: A lógica da pesquisa científica.

estocásticas híbridas para lidar-se com o problema do raciocínio realizado sobre incertezas. Estudos correlatos a este propuseram métodos de inferência para Redes Fuzzy-Bayesianas como solução às estruturas especificadas por variáveis concebidas na forma dicotômica, incorporando ajustes na imprecisão implícita no conhecimento probabilístico da rede modelada para representar um domínio em questão (BRIGNOLI, 2001) e (TIBIRIÇÁ, 2005).

É plausível discutir sobre a acurácia e a eficiência de métodos de raciocínio fuzzy-bayesiano limitados a formatos dicotômicos quando aplicados em domínios que descrevem variáveis de comportamento dinâmico acentuado no que tange a evolução ou transição dos seus estados associados a conceitos subjetivos ou superpostos.

Uma solução ótima é aquela que converge para assegurar uma classificação fuzzy-bayesiana com destaque à qualificação dos resultados obtidos quando a inferência é realizada nos estados limítrofes que justificam alto grau de imprecisão no modelo especificado.

Almeja-se, em princípio, que o modelo de inferência que se propõe a elaborar nesta pesquisa investigue o mecanismo de raciocínio ideal para que a classificação fuzzy-bayesiana apresente resultados, em termos de distribuição de probabilidades, que retratem a realidade do domínio, orientando a tomada de decisão e minimizando discrepâncias em relação ao conhecimento efetivo do especialista humano.

A perspectiva de lidar com variáveis de formas não-dicotômicas e a análise da contribuição do *Princípio da Superposição de Estados* para a descrição de conceitos superpostos tendem, supostamente, assegurar a concepção de um novo modelo de inferência fuzzy-bayesiano capaz de raciocinar com melhor eficácia quando da transição abrupta de estados e de seus valores de probabilidade que explicitam o conhecimento em questão.

A essência da pesquisa em termos da relevância maior do modelo de inferência fuzzy-bayesiano é fornecer resultados probabilísticos que retratem uma classificação mais natural possível, com maior grau de correlação entre a curva de distribuição destas probabilidades (conhecimento modelado e inferido) e o padrão comportamental heurístico realizado pelo especialista humano quando raciocina sobre esta dinâmica de incertezas.

Esta classificação dita – mais natural, acentua significativamente o valor semântico do conhecimento probabilístico resultante do processo de inferência desenvolvido nesta pesquisa. A inserção da capacidade de efetuar raciocínio heurístico no modelo de inferência proposto aproxima-se em muito do processo cognitivo humano de especialistas em processo de tomada de decisão, enfatizando aqui, a atividade de diagnose médica.

As afirmativas anteriores descreveram os termos da relevância da pesquisa em caráter mais essencial, ou seja, focando-se diretamente no objeto central da pesquisa que é a elaboração de um modelo de inferência destinado a suportar o raciocínio sobre incertezas num cenário cuja atividade do especialista é intensiva em conhecimento.

A conjuntura do modelo, como sendo uma solução em termos de resultado de pesquisa tecnológica, é voltada a apoiar o especialista médico no processo de Classificação do Risco Metabólico em crianças e adolescentes. Neste cenário de atuação do médico pediatra, as variáveis manipuladas, seus valores ou medidas e relações são significativamente dinâmicas ocasionando certa complexidade de análise tornando dificultosa a atividade de classificação em seu aspecto mais cognitivo. Isso é justificável devido a esta atividade ser intensiva em conhecimento e imersa em incertezas.

Esta última proposição permite de certa forma direcionar a relevância do modelo proposto no âmbito das vantagens adquiridas com sua utilização no contexto da Classificação de Risco Metabólico. É propenso avaliar o fato de que as Redes Fuzzy-Bayesianas, oriundas do aprimoramento do modelo clássico, são estruturas convenientes para a modelagem e a explicitação do conhecimento sobre o domínio do especialista médico. Diante da complexidade do cenário que envolve as variáveis associadas ao processo de diagnose, as Redes Fuzzy-Bayesianas permitem a realização do raciocínio dinâmico e oferecem este suporte ao especialista médico, uma vez que este pode averiguar uma situação de Risco frente ao próprio paciente aferido. Sob esta argumentação é plausível que as Redes Fuzzy-Bayesianas sejam interpretadas como ferramentas de simulação em que o especialista pode utilizá-la para melhor orientar os procedimentos ao paciente que seja conferido como aquele numa sequência de estados evoluindo para um cenário de risco (PIRES e SILVA, 2013).

Como o fator imprecisão e a dinâmica da superposição de estados não são suportados pelo processo de inferência bayesiano clássico então torna-se necessário esta alteração estrutural no modelo de representação bayesiano fazendo emergir uma nova dimensão às redes clássicas que serão denotadas por esta pesquisa como Redes Fuzzy-Bayesianas com variáveis de estados não-dicotômicos. Esta nova dimensão oferece a flexibilidade necessária para se modelar esta nova forma de conhecimento.

É oportuno relevar que o modelo a ser proposto possa ser estendido a outros domínios cujas características em torno da problemática do exercício do raciocínio sobre incertezas sejam similares ao da atividade do especialista médico no processo de Classificação de Risco Metabólico.

Sobre esta perspectiva pode-se elucidar a contribuição da tese como solução de pesquisa acadêmica ao campo da Engenharia do Conhecimento.

A priori, para descrever esta vinculação é necessário recorrer e considerar as colocações de Schreiber *et al.* (2002) em sua metodologia *CommonKADS* a qual oferece um referencial teórico e prático para suportar a projeção de Sistemas de Conhecimento. *CommonKADS* é constituído por modelos e planilhas que visam desde a compreensão do contexto do problema até os subsídios que proporcionarão compreender quais os insumos necessários ao projeto do sistema em discussão.

Esta tese vislumbra uma forte aderência ao que descreve Schreiber *et al.* (2002) em seu **Modelo de tarefa** e **Modelo de Conhecimento**. A figura 2 propõe mostrar a inserção desta pesquisa ao contexto da disposição dos modelos que compõe a visão da metodologia *CommonKADS* em termos de contribuição como objeto-parte incorporável às soluções voltadas a processos de raciocínio e classificação diante de conhecimento incerto e acentuadamente dinâmico.

Para concluir o argumento de justificativa desta pesquisa ao campo da Engenharia do Conhecimento é necessária a percepção de que tal modelo proposto será uma “**nova abordagem estocástica**” segundo o que ilustra a figura 2, acoplável ao que já se dispõe de ferramentas voltadas a projetos de Sistemas de Conhecimento, no caso, fazendo-se menção a metodologia *CommonKADS*.

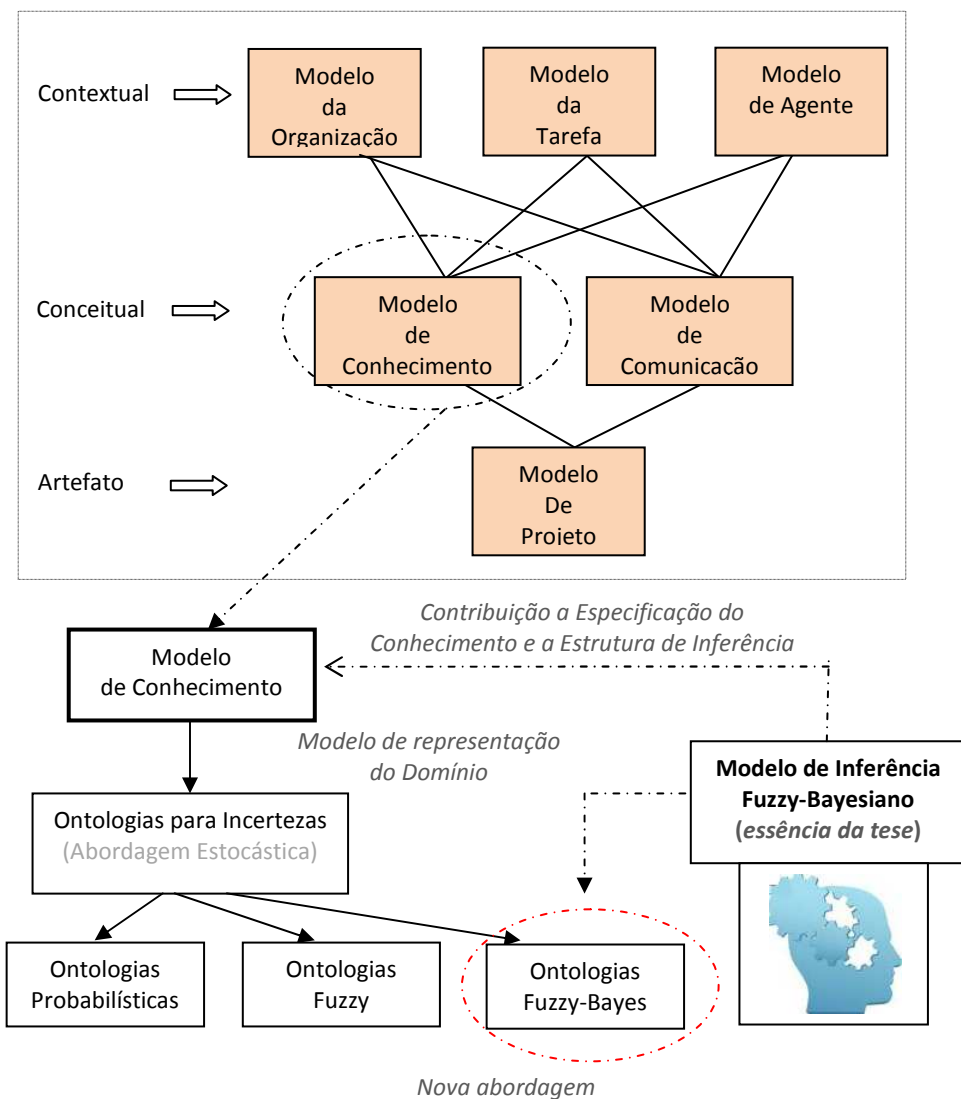


Figura 2 – Associação da pesquisa a Metodologia *CommonKADS*
 Fonte: Adaptado de Schreiber *et al.* (2002)

1.5.3 Ineditismo

O processo de identificação da lacuna de pesquisa no âmbito da temática do tratamento do conhecimento sobre incertezas foi elaborado por meio de uma investigação em quatro bases científicas organizado em duas etapas: a primeira, sendo uma exploração com parâmetros de busca abrangentes aplicada sobre a base *Scopus* e que permitiu vislumbrar um primeiro panorama do Estado-da-Arte das pesquisas relacionadas ao tema e aos objetivos desta tese.

Para melhor qualificar este processo adotou-se de critérios mais parametrizados numa segunda etapa estruturada de Revisão Sistemática da Literatura aplicada sobre as bases *IEEE*, *Elsevier* e *Springer* e que propiciou um conjunto de indicadores bibliométricos e informações relevantes para, a partir das características levantadas pelas produções científicas encontradas, delinear a essência da contribuição desta pesquisa.

As pesquisas mais similares no que refere-se à modelagem para tratamento de conhecimento sobre incertezas numa abordagem híbrida que combine métodos estocásticos segundo as teorias da Probabilidade e da Possibilidade são os trabalhos de Yang (1997), Pan (1999), Baldwin e Tomaso (2003, 2008), Brignoli (2001) e Tibiriçá (2005).

Yang (1997) e, Baldwin e Tomaso (2003 e 2008) focaram diretamente na especificação de modelos de inferência híbridos utilizando-se da Lógica Fuzzy e do método bayesiano clássico de raciocinar diante da incerteza. Pan (1999) discorre em sua obra sobre um formalismo generalizado para atender a representação, o processo de inferência e o aprendizado em Redes Bayesianas Híbridas. O autor propõe que Redes Bayesianas podem especificar em suas estruturas (parte qualitativa) um agregado de variáveis de natureza discreta e contínua. Recorre a modelos de correlação não-linear para ajustar imprecisão nas variáveis de estados contínuos. Apesar de não utilizar exaustivamente todas as etapas propostas pelas técnicas de inferência possibilística e dos pressupostos matemáticos da Lógica Fuzzy o autor contribui significativamente por meio de dois modelos à construção das denominadas Redes Fuzzy-Bayesianas.

O trabalho de Pan (1999) não enfatiza em solução direta a um domínio aplicável e foca seu desenvolvimento num contexto mais computacional, relevando aspectos de complexidade do processamento das Redes Bayesianas. Portanto, considerações em nível semântico não fazem parte do objetivo geral almejado em seu trabalho.

Como solução a um processo de classificação bayesiana necessária para atender a um problema específico de diagnóstico das reações adversas causadas em função do consumo em longo prazo de pequenas quantidades

de resíduos antibióticos em leite, Brignoli (2001) desenvolveu um modelo de inferência híbrido difuso-probabilístico. Em sua proposta, as probabilidades (saída) da Rede Bayesiana eram ajustadas por meio de qualificadores difusos. O modelo servia às redes com estrutura especificada por variáveis dicotômicas. Em sequência a este trabalho, Tibiriçá (2005) utilizou desta abordagem híbrida estendendo sua solução para Redes Bayesianas com múltiplas variáveis, ainda que de natureza dicotômica.

A caracterização do ineditismo desta tese está localizada na abordagem de especificação do modelo de inferência que emprega de modo conjugado a Lógica Fuzzy, o mecanismo de inferência bayesiano, o argumento da Superposição de Estados e, aproxima a proposta sugerindo os constructos necessários para a elaboração de ontologias estocásticas que representem o novo tipo de conhecimento considerado pela problemática levantada. Além disso, os resultados são averiguados em domínio real.

1.6 Metodologia

Esta secção propõe descrever os aspectos associados ao enquadramento metodológico desta pesquisa. Para tal, serão explorados os argumentos que confrontam as definições, as contradições e a forma de percepção de alguns autores no que refere-se à classificação da pesquisa acadêmica.

1.6.1 Tipificação da pesquisa e fatores epistemológicos

No contexto da investigação acadêmica é plausível analisar os conceitos que circundam a terminologia e a significância de duas formas de realização de pesquisa, a tecnológica e a científica. A abordagem aqui realizada irá discorrer sobre as afirmativas de alguns referenciados autores de modo a efetuar-se um paralelo entre as correlações e divergências acerca das peculiaridades da ciência e da tecnologia.

O interesse pelas discussões sob a temática da tecnologia numa perspectiva filosófica é considerado, segundo a análise de Cupani (2006), uma reflexão recente na comunidade acadêmica. O autor recorre à opinião de Bunge (1997), que, como sendo um dos pioneiros da abordagem acerca da Filosofia e Tecnologia, busca a riqueza de assuntos filosóficos detectáveis no contexto da tecnologia no mundo.

Em termos das discussões filosóficas para esta temática, Morais (1988) mostra em sua obra que ter o controle social sobre a tecnologia implica a educação de nossos cidadãos para uma reflexão crítica sobre suas consequências sociais. O autor afirma que isso exige conhecimento

científico e tecnológico que vai além da memorização de sistemas classificatórios, definições e resolução de exercícios, mas a compreensão do papel da ciência e da tecnologia na sociedade, como por exemplo, a compreensão de sua filosofia.

Um importante enquadramento das perspectivas do conceito de tecnologia é apresentado por Cupani (2006) com base na proposta de Carl Mitcham que descreve: 1 – a tecnologia como certo tipo de objetos, denotando a idéia daquilo que se destina meramente a produção de artefatos; 2 – como uma classe específica do conhecimento humano, o saber tecnológico; 3 – como um conjunto de atividades para a produção e uso de artefatos; 4 – como uma manifestação de determinada vontade do ser humano em relação ao mundo.

Esta classificação pode ser significativa ao tentar estabelecer uma distinção clara entre o conceito e atribuição da ciência em relação aquilo que se define como conhecimento tecnológico e sua contribuição material em benefício à sociedade numa perspectiva mais pragmática da aplicação do conhecimento.

Um reforço à classificação anteriormente elucidada pode ser observado na seguinte afirmativa:

“Se preferir, a tecnologia pode ser vista como o campo do conhecimento relativo ao projeto de artefatos e a planificação de sua realização, operação, ajuste, manutenção e monitoração, à luz do conhecimento científico” (BUNGE, 1985, p. 231).

Cupani (2006) sugere um paralelo entre uma análise distintiva da conceituação de ciência e tecnologia ao mesmo tempo em que busca correlacioná-los. A afirmativa de Bunge, trazida pelo autor, revela a preocupação com esta correlação, ou seja, nota-se a tentativa de estabelecer que a tecnologia seja um produto da aplicação de descobertas científicas ou que depende da existência da formulação de uma base teórica. Esta análise é oportuna para uma abordagem sobre a tecnologia vista como a ciência em aplicação.

Para Cupani (2006), as teorias sobre a relação Ciência-Tecnologia correspondem à visão de vários historiadores, que denotam tecnologia como ênfase na produção de artefatos e não na base teórica, sem necessitar de processos de pensamento.

Cupani (2006) apresenta claramente certa dissociação entre os dois modos de conhecimento, científico e tecnológico, ou, o que se poderia caracterizar como uma independência de ambos. O autor refere-se ao fato de que, ao longo da história do desenvolvimento do conhecimento humano,

muitas conquistas foram oriundas de descobrimentos científicos, com fortes bases teóricas elaboradas, como por exemplo, no campo das construções das pirâmides, que certamente necessitou de formulações matemáticas. Por outro lado, observaram-se inúmeros descobrimentos que não partiram de formulações analíticas, de bases teóricas, mas, de meras experimentações em que seus resultados positivos contribuíram para a formalização de certo tipo de conhecimento, como é o caso da consolidação do conhecimento em termodinâmica, que originou-se de uma invenção puramente tecnológica, a máquina a vapor.

Estas exemplificações parecem contribuir para desvincular qualquer relação de dependência entre conhecimento científico e conhecimento tecnológico. Contudo, não sugerem que ambos não possam estabelecer uma relação de causa-efeito, ou seja, ciência propicia embasamento destinado à produção tecnológica e tecnologia ou invenções tecnológicas podem contribuir para formulações bem elaboradas que sustentarão explicações à validação de conhecimento científico.

Na busca da metodologia é oportuno refletir a panorâmica situada diante do investigador no campo da Engenharia do Conhecimento. Concepções de projetos de artefatos ou a formulação de bases teóricas que nortearão estas concepções exigem do engenheiro do conhecimento uma formação e uma visão transdisciplinar Schmalhofer (1992) para poder atuar no espaço do problema com ampla sustentação, assegurando-lhe desempenho e clareza na elaboração de soluções.

A importância da recorrência às contribuições dadas a partir do estudo e da proposta da transdisciplinaridade no campo da investigação científica e tecnológica é fazer com que esta abordagem estabeleça um nível de transgressividade em relação à busca do saber.

A transdisciplinaridade contribui para uma solução de problema conjunto que é mais do que uma justaposição, mais do que colocar uma disciplina ao longo da outra. Nowotny (2010) afirma que: *“uma disciplina não sabe mais do que todas as outras disciplinas”* e que o conhecimento, bem como a especialização é transgressivo.

Sob este aspecto, Nowotny (2010) propõe discorrer sobre o denominado Modo 2 de produção do conhecimento. O autor afirma ser uma forma de conhecimento que emerge uma nova maneira de pensar sobre ciência, a qual, muitas vezes, é descrita em termos disciplinares. A autora refere-se à necessidade de outra linguagem para descrever o que está acontecendo num processo de investigação. Mostra também que a integração e a coerência constituem uma espécie de nova forma de produção de conhecimento.

Esta última consideração estabelecida por Nowotny (2010) pode ser interessante para caracterizarmos o próprio perfil de formação do pesquisador em Engenharia e Gestão do Conhecimento e a maneira transgressiva do engenheiro do conhecimento atuar em sua investigação, tentando compreender, explorar e gerar novas categorias de conhecimento.

Poder-se-ia sugerir que este recurso semântico da transdisciplinaridade, denominado de transgressividade é muitas vezes necessário para se almejar resultados satisfatórios na produção de determinado tipo de artefato tecnológico, ao invés de se limitar a conhecimentos restritos de determinadas teorias como pressupostas para apoiar esta produção.

Araújo (2012) quando baseia-se nos princípios epistemológicos assegurados pela Filosofia de Popper para discorrer sobre a agregação dos métodos quantitativos e qualitativos, vem, de certo modo, a propor o desenvolvimento de uma postura transgressiva do investigador.

Para alcançar o nível de transgressividade é importante o desenvolvimento do denominado *pensamento complexo*. No contexto da evolução das correntes filosóficas a Complexidade é uma forma de pensamento em conformidade com a contemporaneidade e diz respeito ao modo transdisciplinar de se estabelecer critérios de conduta para o processo de investigação social.

Morin (2005) introduz o conceito de complexidade como aquilo que ele afirma ser o “tecido” (*complexus*: o que é tecido junto) de constituintes heterogêneas inseparavelmente associadas, ou seja, coloca o paradoxo do *uno* e do *múltiplo*. O autor afirma após esta primeira explanação que a complexidade é efetivamente o tecido de acontecimentos, ações, interações, retroações, determinações, acasos, que constituem nosso mundo fenomênico. Morin (2005) estabelece que a complexidade se apresenta com os traços inquietantes do emaranhado, do inextricável, da desordem, da ambiguidade, da incerteza e por esta razão que o conhecimento necessita ordenar os fenômenos rechaçando a desordem, afastando o incerto, ou seja, deve selecionar os elementos da ordem e da certeza, precisar, clarificar, distinguir, hierarquizar, entre outros.

Morin (2005) considera a Complexidade como uma filosofia que tende a utilizar uma pluralidade de idéias para se alcançar os objetivos desejados no processo investigatório.

A complexidade e o desenvolvimento do pensamento complexo ou sistêmico são tratados em várias instâncias em termos das ciências sociais. Como observado na última referência, Morin (2005) discorre sobre a complexidade numa esfera mais filosófica situando o investigador em posição capaz de compreender o caos e o todo por meio da compreensão de

suas partes e as interligações entre estas partes. Contudo, outros autores exploram a complexidade em instâncias diferenciadas, como é o caso de Maturana e Varela (1995) em sua obra – *A Árvore do Conhecimento*. Nesta, o autor utiliza a visão sistêmica e o pensamento complexo no contexto biológico para compreender os efeitos resultantes dos denominados *acoplamentos estruturais*, desde o nível molecular até sua instanciação ao nível mais elevado das relações sociais.

Outra análise da aplicação do raciocínio sistêmico é discutida por Senge (1990) que acentua a importância da visão sistêmica aplicando seu conceito nas organizações empresariais. Para o autor, que estabelece as denominadas - *cinco disciplinas*, fundamentais para processos de Aprendizagem Organizacional, a quinta disciplina é o raciocínio sistêmico, cujo autor reconhece que as empresas e os outros feitos humanos são sistemas, e como tal, seus componentes estão conectados por fios invisíveis de ações. Ao se enxergar estes “fios invisíveis” é que estamos aplicando a visão sistêmica.

Contrastadas as características da pesquisa científica e da pesquisa tecnológica no processo de investigação acadêmica, segundo as opiniões convergentes no trabalho de Cupani (2006), é possível compreender e tipificar a presente tese como sendo uma *pesquisa tecnológica*. Esta classificação está aliada ao objetivo de se disponibilizar um modelo de solução ao processo de raciocínio clínico (inferência) que possa oferecer suporte a decisão do especialista médico em tarefa intensiva em conhecimento. Em consonância com Cupani (2006) pretende-se disponibilizar um artefato, mesmo que na forma abstrata representada por uma conjectura matemática, contudo, em sua essência, aplicável sob uma base de dados que possa mostrar indicadores fundamentais para a classificação de Risco Metabólico no processo de diagnose clínica pediátrica.

Entretanto, convergindo com Cupani (2006) quando este não nega o fato da pesquisa científica e da pesquisa tecnológica poderem estabelecer uma relação do tipo causa-efeito, a presente pesquisa, ao disponibilizar tal conjectura matemática de suporte ao raciocínio clínico, poderá também contribuir com o incremental teórico destinado aos esquemas formais para tratamento do conhecimento estocástico.

De um ponto de vista epistemológico é necessário salientar que esta pesquisa investigará os elementos necessários para sua concepção por meio da aplicação do raciocínio complexo, adotando-se de conduta transdisciplinar.

1.6.2 Aderência em contribuição a Engenharia do Conhecimento

Nesta unidade mostrar-se-á os elementos de pesquisa associados aos propósitos indicados pelos objetivos específicos da pesquisa que denotarão a aderência da presente contribuição de tese ao conjunto de soluções disponibilizáveis pela Engenharia do Conhecimento.

Notoriamente, o conhecimento é o objeto central das pesquisas acadêmicas de cunho correlato a esta. Todos os esforços convergem na busca por teorias e tecnologias que possam propiciar a aquisição, o armazenamento, o compartilhamento e a disseminação do conhecimento humano.

Inicialmente, é propenso observar alguns fatores e elementos associados ao conhecimento, conforme ilustrado nas figuras 3, 4 e 5:



Figura 3 – Noções associadas ao conhecimento

Fonte: Adaptado de Navega (2002)

Alguns termos da figura 3 associados ao conhecimento apresentam características que serão exploradas nesta pesquisa, a exemplo, os termos – **certeza/dúvida**. O problema da incerteza manifestada no domínio da atividade de diagnóstico clínico é a problemática motivadora da investigação, manifestada sobre imprecisões e plausibilidade. Observa-se ainda o termo – **crença**. De fato, as Redes Bayesianas são estruturas de

representação do conhecimento baseado em informação disposta sobre a forma de probabilidades e assim sendo, também são modelos baseados em crença. Cabe também destacar o termo – **evidência**, neste caso, a informação observada no mundo exterior que serve de entrada ao processo de raciocínio probabilístico e que consequentemente leva às conclusões dispostas sobre a forma de hipóteses.

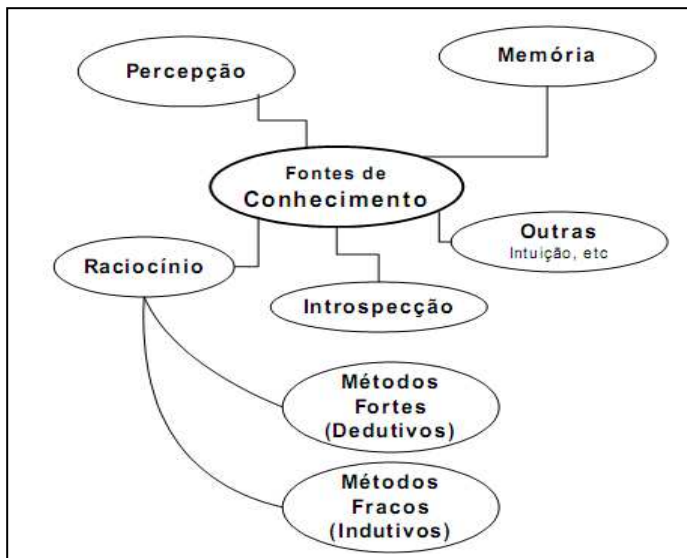


Figura 4 – Origens do conhecimento
Fonte: Adaptado de Navega (2002)

A figura 4 elucida o termo – **raciocínio** como tendo a maior relação com o propósito do modelo a ser desenvolvido por esta tese. A conjectura que se propõe disponibilizará na sua essência uma forma de realizar o suporte ao raciocínio sobre incertezas num cenário em que o especialista emprega um esforço cognitivo acentuado por ser uma atividade intensiva em conhecimento, baseado em dados, em experiência, em aproximações, em crenças.

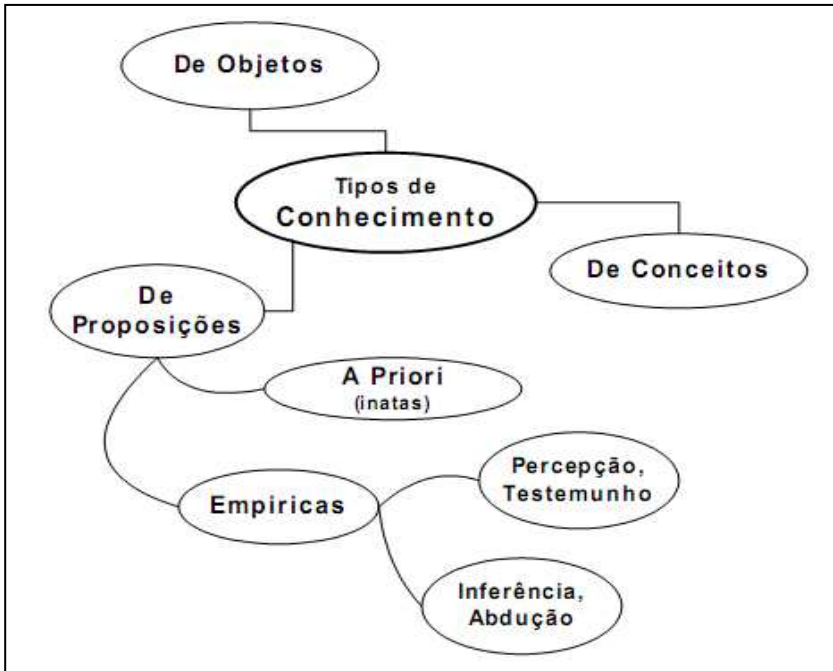


Figura 5 – Tipos de conhecimento
 Fonte: Adaptado de Navega (2002)

Na figura 5 são observados vários termos importantes associados com os objetivos desta pesquisa para com o avanço teórico-tecnológico da Engenharia do Conhecimento voltada ao tratamento das incertezas. Pode-se destacar o termo – **a priori**, que no caso desta pesquisa será um tipo de conhecimento especificado por probabilidades e que denotará o conhecimento sob a forma de crença. O termo mais relevante na figura 5 é **inferência**, por tratar-se diretamente dos objetivos desta pesquisa em construir um modelo de suporte a decisão em tarefa intensiva em conhecimento num cenário sobre incertezas.

O termo *inferência* é amplamente utilizado nesta pesquisa e frequentemente descrito em trabalhos focados no desenvolvimento de (SBC) *Sistemas Baseado em Conhecimento*. É oportuno enfatizarmos sua significância como componente funcional destes sistemas segundo a visão relatada por Schreiber, Wielinga and Hoog (1994). Ao situar o emprego da *Inferência sobre o Conhecimento* em projetos de *KBS* por meio do *framework – CommonKADS*, o autor afirma ser irrelevante a forma em que

o processo de inferência ocorre (cálculo, regras), ou seja, irrelevância esta para fins de modelagem do conhecimento. Para Schreiber, Wielinga and Hoog (1994) estes aspectos constituem a parte interna do processo de inferência que poderá necessitar de técnicas computacionais complexas.

Esta afirmativa dada por Schreiber, Wielinga e Hoog (1994) contribui para um pressuposto elementar desta pesquisa conforme elucidado pela figura 2: se para a metodologia *CommonKADS* é irrelevante o aspecto operacional interno de um modelo ou processo de inferência, então é propício reafirmar a relevância do modelo construído nesta pesquisa como componente acoplável a *frameworks* voltados para projetos de SBC, pois desta forma oferecerá suporte a representação e a inferência que se fará sobre o conhecimento incerto, em questão.

Expostas as terminologias acima relacionadas com o estudo e a exploração do conhecimento é conveniente relevar a **aderência** deste trabalho como tese no âmbito da Engenharia e Gestão do Conhecimento. A figura 6 retrata os elementos, fatos e objetos da pesquisa que sugerem esta aderência.

Na ilustração propõe-se a inserção do Engenheiro do Conhecimento no espaço da solução para o problema e sua atuação demanda uma relação com:

- a) O especialista humano, no caso, o médico, o qual exerce atividade intensiva em conhecimento. Este profissional precisa de suporte (teorias e artefatos) que lhe proporcione um caminho para alcançar a eficiência e a eficácia na tomada de decisão diante da complexidade das informações oriundas de fontes munidas de incertezas;
- b) O cenário de incertezas, o qual apresenta fontes de informação aferidas pela atuação do médico na essência de sua atividade clínica, bem como do conhecimento já explicitado em planilhas, tabelas ou outras formas estruturadas de armazenamento e representação;
- c) Ferramentas da Engenharia do Conhecimento, as quais oferecem soluções percebidas pelo Engenheiro do Conhecimento em sua capacidade de buscá-las e integrá-las sistematicamente numa proposta transdisciplinar de utilizá-las em favor à demanda lhe atribuída.

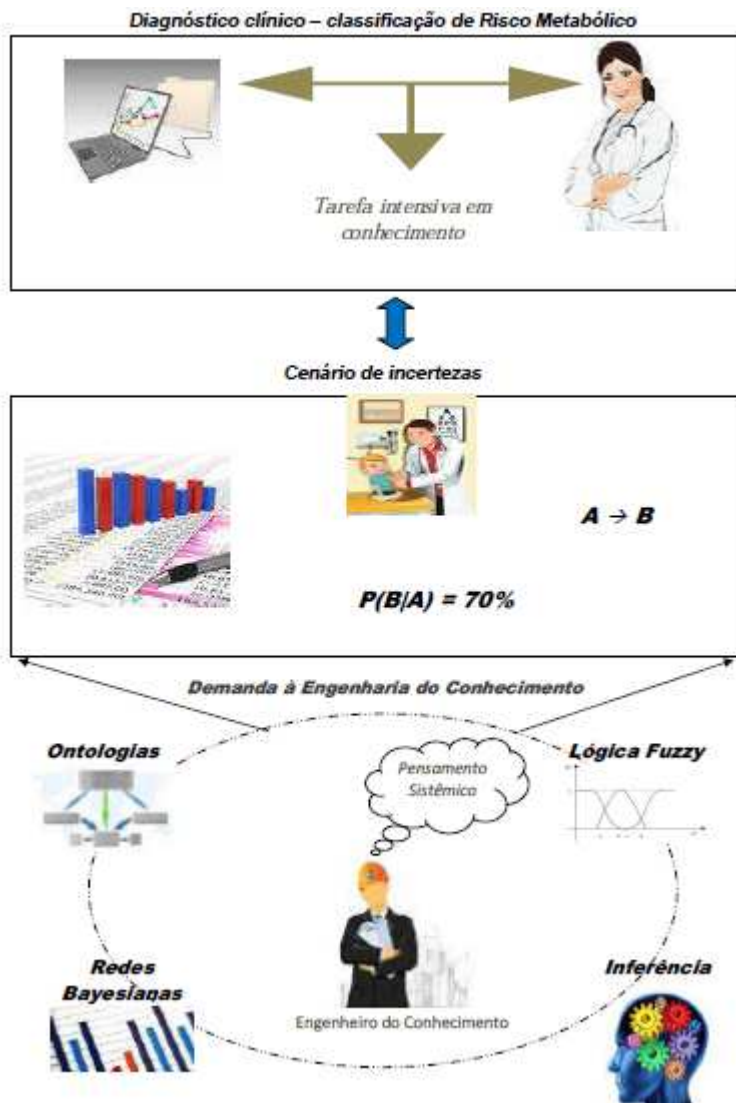


Figura 6 – Elementos da sugestão de aderência da pesquisa
Fonte: (do autor)

1.6.3 Teorias, técnicas e ferramentas

Para alcançar os objetivos da pesquisa serão empregadas as teorias, técnicas e ferramentas em etapas organizadas na forma que segue:

1. Revisão sistemática da literatura para averiguar o Estado-da-Arte das pesquisas no campo do desenvolvimento de modelos de inferência no suporte ao raciocínio sobre incertezas e o emprego das abordagens estocásticas no estudo das ontologias;
2. Análise do cenário do problema cujo domínio será a área de diagnóstico clínico em pediatria voltado à Classificação de Risco Metabólico, sendo esta a intervenção do engenheiro do conhecimento no espaço da solução. Esta etapa necessitará do levantamento, da análise e modelagem da estrutura de representação do conhecimento oriundo de prontuários médicos disponibilizados em planilhas eletrônicas utilizando a técnica de elaboração de Redes Bayesianas;
3. Para analisar as limitações das Redes Bayesianas na classificação de Risco Metabólico serão efetuadas simulações numa Rede Bayesiana já utilizada em experimentos no Hospital Universitário (HU) de Florianópolis mediante a participação de especialista médico pediatra;
4. Desenvolver-se-á um modelo de inferência para o suporte ao raciocínio clínico de Risco Metabólico em crianças e adolescentes utilizando de formulação matemática a partir do emprego do hibridismo entre as técnicas da Lógica Fuzzy para lidar com imprecisões e das Redes Bayesianas para modelar o conhecimento sobre a forma de probabilidade. A conjunção das técnicas propõe gerar uma forma de realizar inferência em Redes Fuzzy-Bayesianas;
5. Para solucionar o problema da dicotomia e estender o modelo para uma forma não dicotômica de representar as variáveis e seus estados a partir do domínio estudado serão empregados, de maneira inspiratória, os pressupostos teóricos do Princípio da Superposição de Estados, da Física Quântica;
6. O modelo será verificado por meio de simulações em planilhas com os mesmos dados simulados na fase de identificação das limitações do modelo bayesiano clássico. O especialista médico fará a interpretação dos resultados para descrever os aspectos semânticos no contexto do domínio e da solução. Portanto, o processo de verificação de resultados será realizado com dados e

com a análise do especialista para assegurar a convergência em relação à acurácia do modelo.

1.7 Organização e Escopo

1.7.1 Estruturação

Na sequência do capítulo 1 que descreve a introdução para o desenvolvimento desta tese serão abordados outros três capítulos.

O capítulo 2 refere-se à Revisão de Literatura que propiciará as bases teóricas necessárias para suportar a elaboração do modelo de inferência proposto e consequentemente sustentar as argumentações que circundarão a veracidade e eficiência da solução à problemática citada anteriormente.

Este mesmo capítulo contemplará todo o processo que utilizou do recurso da Revisão Sistemática, para investigar os principais trabalhos correlatos desenvolvidos de modo a se vislumbrar o atual panorama das abordagens estocásticas de representação do conhecimento sobre incertezas e empregadas como solução às Redes Bayesianas.

Entre os principais pressupostos teóricos a serem investigados estão:

- As ontologias concebidas por modelos estocásticos de representação do conhecimento sobre incertezas;
- As Redes Bayesianas Clássicas como soluções à classificação e suas limitações que motivaram as pesquisas que desenvolveram as Redes Fuzzy-Bayesianas;
- As Redes Fuzzy-Bayesianas e as formas de hibridismo combinando aleatoriedade e imprecisão;
- Inferência fuzzy-bayesiana sobre variáveis dicotômicas;
- O cenário de verificação do modelo a partir da descrição da atividade médica e o contexto da classificação de Risco Metabólico na atuação pediátrica;
- O Princípio da Superposição de Estados e sua instanciação na elaboração do modelo de inferência proposto.

O capítulo 3 descreve as premissas básicas da modelagem, seu desenvolvimento em termos da formalização matemática, supõe os constructos necessários para que o modelo possa oferecer suporte às ontologias estocásticas que representam este tipo de conhecimento e, realiza os testes gerais e simulações com dados provenientes de bases já utilizadas por aplicações construídas com o paradigma clássico das Redes Bayesianas. Realiza-se a comparação dos resultados produzidos pelo modelo em

correlação com a interpretação do especialista frente à atividade intensiva em conhecimento no contexto do diagnóstico clínico.

Por fim, o capítulo 4 apresenta as considerações finais em termos das vantagens e das limitações e ao final, o trabalho contribui com apontamentos que sugerem a continuidade de pesquisas no âmbito da temática.

1.7.2 Delimitações

Conforme já elucidado, a pesquisa limita-se a elaboração de um novo modelo de inferência que ofereça o suporte ao processo de raciocínio num cenário cuja atividade de diagnose clínica é intensiva em conhecimento, ou seja, a classificação de Risco Metabólico em crianças e adolescentes cuja dinâmica das variáveis envolvidas é acentuada, o que motiva a investigação de teorias e técnicas como Superposição de Estados e Lógica Fuzzy.

Sugere-se em nível teórico que esta forma de suporte ao raciocínio sobre incertezas possa servir e acoplar-se a outras ferramentas teóricas voltadas a projeção de sistemas de conhecimento no que refere-se aos modelos de tarefas e de inferência, como é o caso da metodologia CommonKADS.

Em termos operacionais, a acurácia e a eficácia do modelo são verificadas por meio de simulações em planilhas eletrônicas. Não é essencial a elaboração de interfaces avançadas para este propósito, neste caso, o seu desenvolvimento pode ser sugerido para trabalhos de pesquisa no campo das Ciências da Computação.

Serão sugeridos os elementos necessários aos projetos de ontologias estocásticas que desejem avançar com o desenvolvimento sintático e automatizado de representação de conhecimento sobre incertezas segundo o modelo Fuzzy-Bayesiano a ser disponibilizado, contudo, esta sugestão se fará em nível teórico e suprimido, pois entende-se que tal sugestão propiciará novo elemento de pesquisa acadêmica na área de Engenharia de Ontologias ou Ciências da Computação.

2 REVISÃO DE LITERATURA

Este capítulo descreverá os principais pressupostos teóricos que constituirão a base das argumentações para a validação da inserção desta tese em contribuição às soluções da Engenharia do Conhecimento frente às suas demandas.

Associado diretamente a essência da pesquisa, exploram-se as bases teóricas, suas soluções e limitações no que refere-se ao tratamento de incertezas em domínios caracterizados por aleatoriedade e imprecisão.

2.1 Engenharia do Conhecimento

2.1.1 Fatores paradigmáticos

O conhecimento tem se denotado como fator essencial para assegurar a sobrevivência da espécie humana. Diante do ritmo acelerado do desenvolvimento das sociedades pertinentes a atual conjuntura da vida moderna é imprescindível o investimento na elaboração dos denominados Sistemas de Conhecimento que possam apoiar processos de aquisição, armazenamento, compartilhamento e disseminação de conhecimentos nos mais diversos domínios. Segundo Nonaka (1998) o conhecimento pode ser visto de várias perspectivas: 1 – um estado de mente; 2 - um objeto; 3 - um processo; 4 - uma condição de ter acesso às informações; 5 - uma capacidade.

A Inteligência Artificial tem contribuído de modo significativo para a elaboração de técnicas computacionais aplicáveis aos processos de gerenciamento do conhecimento. Um paradigma mais antigo da Inteligência Artificial concebeu resultados satisfatórios para as demandas decorrentes daquela época e suas abordagens eram basicamente quatro: IA Simbólica, IA Conexionista, IA Evolucionária e IA Híbrida. Todas estas abordagens disponibilizavam maneiras de se promover algum tipo de manipulação sobre o conhecimento, inspiradas por mecanismos biológicos, como as Redes Neurais Artificiais e os Algoritmos Genéticos, e outras com fundamentação formal a partir da Lógica e da Matemática.

Uma nova concepção acerca da manipulação ou gerenciamento do conhecimento tornou-se necessária para atender às crescentes demandas organizacionais. Os sistemas de conhecimento construídos a partir da visão que os estudiosos tinham em relação ao campo das aplicações de Inteligência Artificial apresentavam-se, na maioria das vezes, descontextualizados das realidades organizacionais para as quais estes sistemas eram implementados.

Uma nova percepção identificou que o gerenciamento do conhecimento não pode ser realizado com implementações desprovidas do entendimento de todo um contexto organizacional. Esta preocupação quanto às limitações dos projetos de sistemas de conhecimento concebidos de maneira *ad hoc*, ou seja, com tarefa direcionada a uma atividade muito específica, como por exemplo, uma Rede Neural para analisar crédito bancário, motivaram o surgimento de um novo paradigma de engenharia para apoiar as demandas da Gestão do Conhecimento.

A nova Engenharia do Conhecimento releva todos os fatos e elementos associados ao objeto que motiva a projeção de um Sistema de Conhecimento e nesta nova forma paradigmática de analisar um problema torna-se indispensável que o engenheiro do conhecimento utilize maneiras transdisciplinares para vislumbrar caminhos que venham a convergir para a solução.

Sob a perspectiva da Complexidade é possível disciplinar a capacidade de compreender o mundo e os princípios ocultos que governam nossa visão das coisas. (MORIN, 2005). O raciocínio complexo pode prover capacidades ao engenheiro do conhecimento para atuar no espaço da solução.

Num contexto prático, Schreiber *et al.* (2002), propuseram uma ferramenta conceitual alinhada com esta nova visão da concepção de Sistemas de Conhecimento. O autor disponibiliza um *framework* denominado *CommonKADS*, baseado em modelos, apresentado na Figura 7.

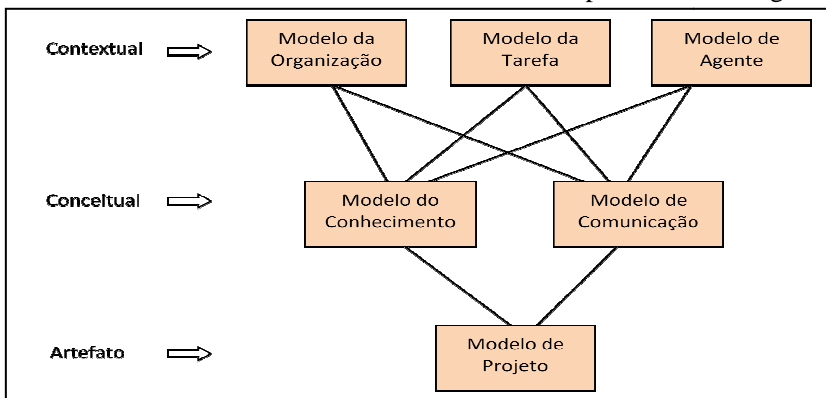


Figura 7 - Modelos da Metodologia *CommonKADS*

Fonte: Adaptado de Schreiber *et al.* (2002)

O importante é compreender sobre os tipos essenciais de conhecimento, conforme elucida Schreiber *et al.* (2002): Conhecimento

Explícito – aquele disponibilizado em documentos, bases de dados, e-mails ou em outra mídia qualquer; Conhecimento Tácito – aquele não documentado, empírico e informal.

De fato, é pertinente observar que a evolução paradigmática para a elaboração de Sistemas de Conhecimento deve ter sido inspirada por visões mais sistêmicas dos elementos que convergem para a formação de um conhecimento. Em termos práticos é notável que o conhecimento alvo de uma aplicação seja gerado pela interação entre elementos dentro de um contexto (ambiente). O próprio *CommonKADS* demonstra as interações entre agentes, tarefas e outros componentes que fazem o conhecimento existir e ser algo possível de manipulação.

Esta última argumentação sugere uma significativa associação entre o novo paradigma da Engenharia do Conhecimento e o emprego da visão sistêmica no exercício da projeção dos Sistemas de Conhecimento.

2.1.2 Ferramentas de suporte aos processos de diagnose médica

No âmbito do suporte ao diagnóstico médico e das práticas de decisão clínica os Sistemas de Conhecimento tiveram uma inserção positiva e seus projetos têm sido bem aceitos pela comunidade de especialistas assim como o referenciado sistema Mycin (Shortliffe, 1976), que apoiava os especialistas nos processos de aconselhamento de diagnóstico e terapia sobre doenças infectocontagiosas.

Um exemplo de sistema mais recente pode ser encontrado em Widman (1998), o QMR (*Quick Medical reference System*) que realiza diagnóstico em vários segmentos da medicina interna. Este sistema apresentou resultados similares aos dos especialistas em casos tratados. Em conformidade com a aplicação das técnicas de Inteligência Artificial o QMR utiliza inferência baseada em lógica e cálculo de probabilidades.

Widman (1998) apresenta ainda outros exemplos de Sistemas Especialistas no suporte médico tais como: TraumID para apoio ao diagnóstico de trauma no tórax, Sistema para prognóstico de doenças crônicas do fígado, DXPlain, um sistema para diagnóstico em medicina interna.

A Engenharia do Conhecimento tem recorrido significativamente ao estudo e a aplicação do uso de estruturas de representação de conhecimento sobre a forma de *ontologias*. Sua empregabilidade em Sistemas de Conhecimento denotou forte interesse em sua exploração, a exemplo, no contexto da atividade médica em lidar com compartilhamento e padronização de processos de diagnose.

É notável nos últimos anos o acentuado avanço das pesquisas e o incremento de soluções voltadas às mais diversas áreas do conhecimento humano que recorrem ao uso das ontologias como forma de representar e de compartilhar este conhecimento inerente à necessidade em questão.

O termo – ontologia e as concepções sobre sua origem remontam um passado de reflexões filosóficas que retratavam nossas curiosidades mais primitivas acerca da necessidade de dar o significado às coisas do mundo, suas definições, classificações e relações, segundo as observações e postulados da época de pensadores como Aristóteles (STUDER *et al.*, 1998).

Estes notáveis precursores do desenvolvimento de ciência moderna talvez jamais imaginassem que em uma época futura tão distante suas premissas mais elementares em torno do estudo das ontologias tornar-se-iam imensamente discutidas e utilizáveis no âmbito das soluções teóricas e práticas para a manipulação do conhecimento humano.

Na atual conjuntura da disponibilização de metodologias e de soluções em software oriundas da Inteligência Artificial e da Engenharia do Conhecimento observa-se o potencial uso das ontologias como estruturas propícias a representação, armazenamento, recuperação e compartilhamento do conhecimento em um domínio específico frente a uma demanda (PÉREZ, LÓPES e CORCHO, 2004).

Numa forma interdisciplinar de empregar o uso de ontologias com ferramentas computacionais, matemáticas e estatísticas, inúmeras soluções têm assistido necessidades nas áreas de biologia (Bard and Rhee, 2004), gestão de empresas, *e-commerce*, engenharia, química, entre outras, conforme elucidado em (Pérez, López e Corcho, 2004) no que tange a representação e compartilhamento de conhecimento dentro de uma especialidade, objetivando a otimização em apoio a processos de tomada de decisão, por exemplo, em atividade de classificação e diagnose médica (Lopes, 2011).

Gruber (1993) descreve ontologia como “*uma especificação explícita de uma conceitualização*”. A partir desta afirmativa, Borst (1997) a redefine: “*Uma ontologia é uma especificação explícita e formal de uma conceitualização compartilhada*”. E assim, em conformidade com várias outras definições retratadas na obra de (Pérez, López e Corcho, 2004), normalmente, autores formalizam suas definições sobre ontologia descrevendo o termo – conceito e suas derivações.

A figura 8 ilustra alguns elementos constituintes de uma especificação de ontologia na área médica.

Segundo Pires (2007), a troca e o compartilhamento de informações clínicas entre sistemas de informação em saúde é um importante aspecto

visando o aprimoramento desses sistemas com novas atividades de obtenção de segunda opinião diagnóstica de diferentes médicos, mesmo quando estes não estão disponíveis no momento da requisição.

Ainda em (Pires, 2007), o autor refere-se ao problema da interoperabilidade semântica causada por sistemas de terminologias diferentes e propôs em seu trabalho à construção de uma ontologia denominada SODOnt, que define um vocabulário comum para médicos, um conjunto de dados e suas estruturas para outros softwares clínicos que precisam trocar informações em um ambiente compartilhado, orientado a serviço e computacionalmente distribuído.

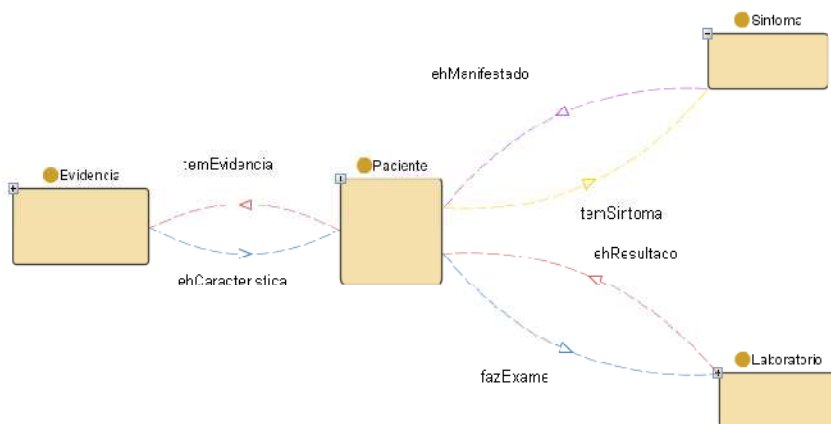


Figura 8 – Relações entre classes em uma ontologia médica
Fonte: Lopes (2011)

2.1.3 Suporte metodológico das Ontologias

No âmbito da Engenharia de Ontologias existem diversas metodologias para a concepção, especificação, implementação, manutenção e todas as fases que compõem um ciclo de vida de uma ontologia. Cenários complexos em descrição de conceitos e relações, como é o caso daqueles provenientes da atividade clínica, cuja incerteza é fator expressivo no processo de tomada de decisão, necessitam de metodologias capazes de proporcionar ao Engenheiro do Conhecimento uma sequência eficaz e eficiente de determinar os insumos necessários ao projeto de uma ontologia.

Sobre este aspecto, Rautenberg *et al.* (2010) propôs uma interessante ferramenta orientada ao projeto de ontologias, o *ontoKEM*. O autor incorpora em sua ferramenta uma metodologia denominada

METHONTOLOGY que prevê um ciclo de vida baseado em prototipagem de ontologias, numa forma similar aos processos de Engenharia de Software, envolvendo as etapas de *especificação*, *conceitualização*, *formalização*, *implementação* e *manutenção*. A figura 9 mostra a representação da metodologia *METHONTOLOGY*:

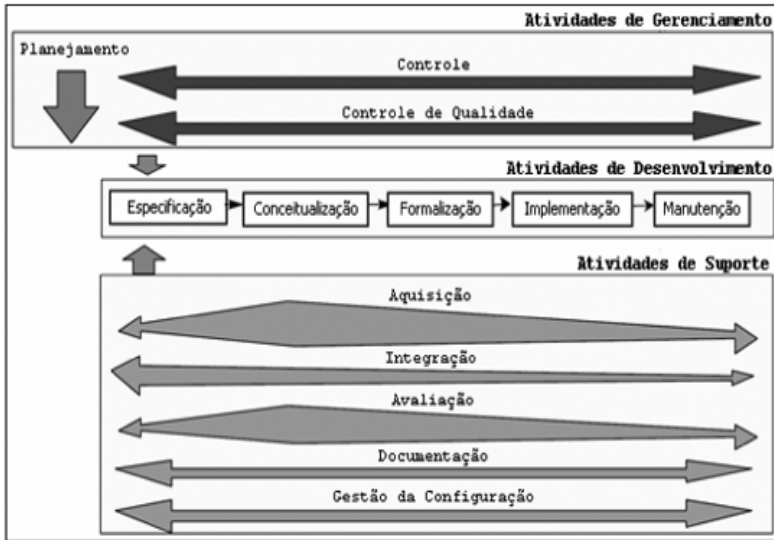


Figura 9 – Representação da metodologia *METHONTOLOGY*

Fonte: Rautenberg *et al.* (2010)

Rautenberg *et al.* (2010) discorre em seu trabalho sobre os artefatos de documentação que são gerados pela ferramenta *ontoKEM*, os quais compreendem:

- **O Escopo da Ontologia:** que registra respostas às questões sobre a abrangência do domínio e a utilidade da ontologia;
- **Questões de Competência:** permite identificar conceitos, propriedades, relações e instâncias da ontologia;
- **Vocabulário completo:** determinação das classes, relações, propriedades de dados, instâncias e restrições. Este componente permite o consenso das definições por parte dos engenheiros de ontologias e o especialistas de domínio;
- **Hierarquia de Classes:** nesta etapa o *ontoKEM* gera dois artefatos - um Gráfico de Hierarquia de Classes e um Dicionário de Classes.

O trabalho desenvolvido por Rautenberg *et al.* (2010) sugere de maneira clara a importância de todo o formalismo envolvido no projeto de construção de uma ontologia e como estas estruturas de representação de conhecimento podem servir aos propósitos do Engenheiro do Conhecimento.

Ao observar os propósitos de cada artefato de documentação elucidados em Rautenberg *et al.* (2010) é propenso induzir uma reflexão acerca do uso destes artefatos para descrever ontologias no domínio do diagnóstico médico que expressam o conhecimento por meio de conceitos estocásticos, com variáveis intrínsecas de relações causais e subjetivas.

A metodologia utilizada pelo *ontoKEM* pode nortear a busca pelos constructos necessários a concepção de um tipo de ontologia estocástica. Assim sendo, esta suposta ontologia proveria uma estrutura capaz de ser operacionalizada por ferramentas apropriadas ao processo de representação e inferência sobre incertezas.

Adiante, esta pesquisa irá explorar algumas destas ferramentas de tratamento estocástico do conhecimento. A priori e de maneira hipotética apenas será elucidada a idéia da figura 10:

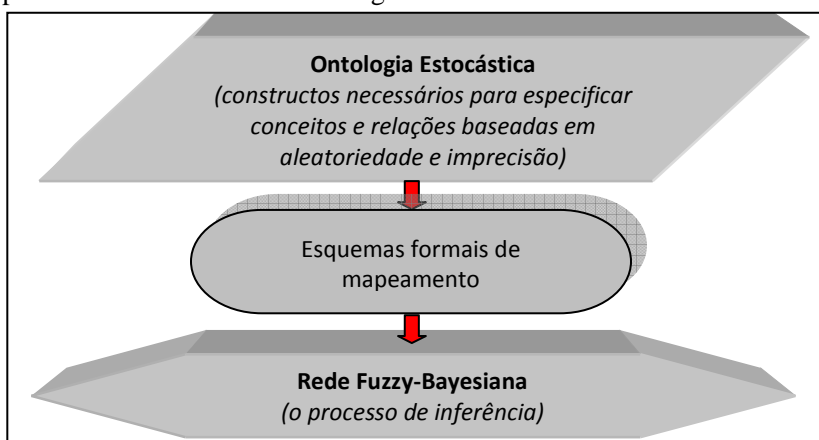


Figura 10 – Possível mapeamento de uma Ontologia para uma RFB

Fonte: (do autor)

Sobre a ótica da utilização das ontologias como formas de representação de conhecimento estocástico é importante salientar a vantagem que se pode alavancar em termos do compartilhamento deste conhecimento entre especialistas, por exemplo, médicos em atividades intensivas de diagnose que necessitam de uma melhor qualificação

semântica nos resultados obtidos pelo processo de raciocínio sobre o domínio em que atuam.

2.2 O especialista e atividade intensiva em conhecimento

Uma atividade intensiva em conhecimento é aquela produzida ou integrada por empresas ou por atores do setor público, nos diversos contextos organizacionais, de manufatura ou de serviços, paralelamente a produção manufatureira ou enquanto serviços autônomos (OCDE, 2003).

A afirmativa anterior parece denotar uma definição mais voltada ao contexto das organizações em termos de produção de artefatos e do trabalho manufatureiro. Contudo, em sua essência é plausível de uma instanciação para organizações cuja atividade ou trabalho não necessariamente é efetiva em esforço fisiológico, por exemplo, hospitais e clínicas, cujos atores (médicos, por exemplo), desempenham intensa atividade cognitiva quando da realização de diagnósticos em seus pacientes.

É factível que todo tipo de trabalho possui ou está vinculado a algum tipo de conhecimento inerente a atividade ou tarefa que está sendo desenvolvida. Contudo, esta relação não implica necessariamente que se esteja realizando um *trabalho de conhecimento*.

Em conformidade com Nonaka e Takeuchi (1997), o trabalho de conhecimento exige dos profissionais um alto nível de experiência e de habilidade cognitiva para executar determinada tarefa. Os autores propuseram uma classificação para os trabalhadores que criam conhecimento nas organizações, conforme mostra a tabela 1:

Tabela 1 - Trabalhadores que criam o conhecimento

Criadores de Conhecimento	Atividades	Exemplos de Trabalhadores
Operadores	Acumulam e geram conhecimento tácito. Suas habilidades são adquiridas com a experiência.	Profissionais que atuam em produção (artefatos).
Especialistas	Acumulam, geram e atualizam conhecimento explícito.	Cientistas, planejadores, analistas.
Engenheiros	Transformam conhecimento: tácito \leftrightarrow explícito	Gerentes de nível médio.
Gerentes	Gerenciam processos de criação de conhecimento nas organizações.	Gerentes de nível sênior.

Fonte: Nonaka e Takeuchi (1997)

Um trabalhador do conhecimento também pode ser considerado como um *especialista* quando a tarefa a ser desempenhada contém o conhecimento como insumo essencial à execução da mesma.

Para Abel (2001) um especialista é um trabalhador do conhecimento que possui a capacidade de aplicar habilidades cognitivas de modo superior aos demais profissionais daquele domínio no desenvolvimento de uma tarefa e possui uma grande quantidade de conhecimento acerca do objeto. É perito na realização da tarefa.

O trabalho desenvolvido por especialistas médicos no que refere-se à tarefa de efetuar um diagnóstico ao paciente exige intensa atividade cerebral que desencadeia processos cognitivos, o que, de acordo com Santos (1995) é a parte *não observável* da atividade mental de um trabalhador do conhecimento. Estes processos cognitivos envolvem percepção, memorização, tratamento da informação, tomada de decisão e ação.

Portanto, é oportuno evidenciar que muitas ferramentas da Engenharia do Conhecimento podem oferecer suporte à qualificação da atividade de diagnose médica, em especial no que trata do uso da informação e no processo final de tomada de decisão, a qual empenha imensa atividade de raciocínio, principalmente quando depende do volume de variáveis envolvidas e a natureza destas variáveis, por exemplo, variáveis imersas em incertezas, refrisando a motivação por busca de solução nesta pesquisa.

2.3 O cenário e a atividade clínica na diagnose do Risco Metabólico

A proposta deste capítulo é uma contextualização mais detalhada do ponto de vista técnico da atuação do especialista médico no exercício da atividade clínica de diagnose e de Classificação do Risco Metabólico em crianças e adolescentes. O texto que segue é resultante dos apontamentos de artigos especializados e analisados por Pires (2012) que convergem para uma descrição de elementos, fatos e procedimentos relacionados ao processo clínico em relevância no domínio da aplicação desta pesquisa.

A obesidade em crianças e adolescentes é hoje um grave problema de saúde pública sendo que, sua prevalência vem aumentando de forma alarmante e desproporcional no mundo, incluindo os países pobres onde a desnutrição era tradicionalmente prevalente. Segundo dados da OMS, no ano de 2010, 42 milhões de crianças com até 5 anos de idade estavam acima do peso. O Brasil acompanha essa tendência. Em nosso país, cerca de 30% das crianças entre 5 e 9 anos estão dentro da faixa de sobrepeso, e 14%

são obesas, sendo que mais de 50% da população com mais de 20 anos apresenta excesso de peso (WORLD, 2011) (IBGE, 2013).

Compreender, conhecer e identificar fatores de risco para obesidade infantil é fundamental para preveni-la e assim intervir nas co-morbidades dessa enfermidade com consequente redução da morbimortalidade relacionada à obesidade e enfermidades consequentes a ela como Diabetes tipo 2 (DM2), Hipertensão Arterial Sistêmica (HAS), Doenças Cardiovasculares (DCV) entre outras. Os determinantes da obesidade são complexos e que perpassam por ambiências diferentes como: social, cultural e pessoal. O denominador comum está centrado na globalização e a enorme velocidade da informação que padronizam modos de vida, com mudanças semelhantes em todo o mundo, mostrando um padrão alimentar inadequado associado à inatividade física cada vez maior. A chave para a compreensão e, combate está na identificação de fatores de risco empregando uma abordagem ecológica focada em sociedade, comunidade, família, escola, e do indivíduo. Ou seja, usando o denominador comum, para sensibilizar e alertar a sociedade como um todo incluindo a área da saúde e da educação (RAMIREZ *et al.*, 2013) (SKOUTERIS *et al.*, 2011).

Um dos períodos críticos para o desenvolvimento da obesidade tem sido observado em crianças de sete a nove anos de idade e o início precoce do rebote da adiposidade. É preocupante o aumento da prevalência de sobrepeso e obesidade nessa fase devido à associação com complicações metabólicas, cardiovasculares, pulmonares, ortopédicas, psicológicas e algumas formas de câncer, decorrentes da obesidade na idade adulta. Outro ponto relevante é quanto à prevalência da gordura corporal excessiva na infância e à precocidade com que podem surgir os efeitos danosos à saúde, além das relações existentes entre obesidade infantil e sua persistência até a vida adulta. Estudos tem demonstrado que o excesso de peso na infância é um importante fator de risco para o desenvolvimento da obesidade na vida adulta, ou seja, há um risco aumentado de a criança obesa permanecer nessa condição quando adulta, se comparado aos indivíduos eutróficos (KYULO *et al.*, 2012) (FREEDMAN *et al.*, 2007) (KONES, 2011) (WILLIAMS e GOULDING, 2008).

Vários estudos tem demonstrado que a probabilidade de uma criança obesa se tornar um adulto obeso aumenta com a idade da criança, e com a idade de rebote da adiposidade, independentemente da duração do tempo em que a criança tenha sido obesa (WHITAKER *et al.*, 1997).

Outro estudo mostrou que entre as crianças com sobrepeso (IMC P85 a P95), 50% tornam-se adultos obesos. No grupo de IMC em P95 a P98, 84% dos indivíduos tornam-se adultos obesos, e 34% deles com obesidade grave. Aqueles com IMC > P99, 100% tornaram-se adultos obesos e 65%

com obesidade grave. Esse estudo sugere que há que se ter cuidado e intervir precocemente e o que o P99 do IMC em crianças e adolescentes seja utilizado como critério prognóstico e de alerta, uma vez que detecta um risco muito alto para fatores de risco para doenças cardiovasculares, excesso de peso e desenvolvimento futuro de obesidade grave quando adultos (FREEDMAN *et al.*, 2007) (NOVAES *et al.*, 2012).

Além do IMC outros fatores de risco são importantes para se identificar o grau de risco para o desenvolvimento de uma obesidade grave, DM2 ou Síndrome Metabólico. Entre esses dados, a circunferência abdominal, por refletir de maneira indireta a adiposidade central em crianças e adolescentes, é um bom preditor para o aumento da massa de gordura central (PEDIATRIA, 2012) (FREDRIKS *et al.*, 2005) (TAYLOR; JONES; WILLIAMS, 2000).

Dados de 2597 crianças e adolescentes com idades entre 5 e 18 anos foram coletados através da pesquisa Bogalusa Heart Study, entre os anos de 1992 e 1994. Após avaliar a relação entre fatores de risco (LDL colesterol, VLDL colesterol, triglicérides, glicose, insulina e pressão arterial) e as medidas de IMC e circunferência abdominal, constataram que, o uso do IMC e da CA para predição de fatores de risco para doenças cardiovasculares em crianças e adolescentes tem utilidade clínica significativa (KATZMARZYK *et al.*, 2004).

Pesquisa epidemiológica realizada em Florianópolis, com uma amostra representativa de crianças e adolescentes escolares, concluiu que o excesso de peso é o fator mais fortemente associado à hipercolesterolemia, sugerindo que medidas que visem o controle de peso corporal na infância e adolescência podem ter um impacto importante sobre as doenças cardiovasculares dessa população (GIULIANO *et al.*, 2005).

Em relação ao fator de risco da hereditariedade destacam-se vários estudos mostrando resultados importantes. Em um estudo, prevalência de sobrepeso / obesidade foi de 36,2% nos meninos e 32,7% entre as meninas. A prevalência foi de 56,3% e de 27,5% nos pais e mães, respectivamente. No modelo final, da mãe ($p = 0,001$) e estado nutricional do pai ($p = 0,050$) permaneceram diretamente associado ao sobrepeso / obesidade dos escolares. A prevalência de sobrepeso / obesidade foi 1,58 vezes maior em escolares com mães com sobrepeso / obesidade, e 1,41 vezes maior em escolares com pais com excesso de peso / obesidade, em comparação com mães e pais sem a condição (BERNARDO e VASCONCELOS, 2012) (STAMATAKIS *et al.*, 2013).

A inatividade física é reconhecida como fator de risco para a morbimortalidade e desencadeador das Doenças Crônicas não Transmissíveis (DCNT) que podem e devem ser prevenidas a partir da

infância. Pesquisas que evidenciam a importância da atividade física entre crianças e jovens e entre os benefícios para saúde apresentados por elas estão o aumento da aptidão física, redução da gordura corporal, diminuição de risco de doenças metabólicas e cardiovasculares, promoção da saúde óssea e saúde mental (JANSSEN, 2010).

É possível afirmar também, que a atividade física tem efeitos benéficos sobre níveis de adiposidade naqueles com peso normal, sobre a pressão arterial em jovens normotensos, em níveis de lipídeos e lipoproteínas plasmáticas, sobre fatores não tradicionais de risco cardiovascular (marcadores inflamatórios e função endotelial), e outros componentes mentais além da depressão, tais como ansiedade e auto-conceito (STAMATAKIS *et al.*, 2013) (JANSSEN, 2010).

Frente a esse panorama, onde os distúrbios nutricionais que afetam crianças e adolescentes possuem componente multifatorial, cujo diagnóstico está atrelado ao fator incerteza e considerando pontos de corte e adequada interpretação dos dados coletados, a escolha de recorrer às Redes Bayesianas no suporte ao diagnóstico é devido a sua aplicação bem sucedida em vários Sistemas Especialistas já desenvolvidos dentro da área médica. No entanto, quando a complexidade ou dinâmica do fator incerteza é aumentada, se faz necessário o uso de abordagens mais sistêmicas e, sobre este aspecto, as soluções em Engenharia do Conhecimento, desenvolvidas para a área médica desempenham não somente a função de auxiliar no diagnóstico médico, mas podem também ser utilizadas no treinamento de estudantes de medicina, residentes, médicos da família, entre outros.

Como ferramenta de auxílio ao raciocínio do especialista médico, o modelo a ser induzido a partir das Redes Bayesianas pode abrir um leque de possibilidades no sentido de conduzir o especialista no processo de tomada de decisão conjunta frente a orientação dada ao paciente e, portanto, propiciando uma melhor adesão ao tratamento; gerar gráficos e tabelas para uma visão mais clara do raciocínio clínico; simular situações de prognóstico entre outras.

Segundo Pires (2012), na tomada de decisão vê-se da necessidade de avaliar não somente os dados quantitativos, mas os qualitativos, por mostrarem diagnósticos sobrepostos; casos clínicos, cujo diagnóstico quantitativo fundamentado no escore Z do IMC e CA podem indicar um alerta para risco leve a moderado. No entanto se esses dados quantitativos estiverem próximos ao ponto de corte fica o alerta para um diagnóstico de maior risco, que pode aumentar se somado a outros fatores como HAS ou dislipidemia ou ainda sedentarismo ou erro alimentar, ou história familiar (PIRES, 2012).

No auxílio ao diagnóstico ou tomada de decisão para uma maior investigação, a importância do emprego de ferramentas da Engenharia do Conhecimento no estudo desses dados e das probabilidades geradas como resultados indicadores levariam a um monitoramento mais adequado do processo: saúde doença (PIRES, 2012).

2.4 Representação do conhecimento sobre incertezas

Para iniciar as discussões e a motivação pela busca de ferramentas direcionadas à solução no âmbito da representação do conhecimento em cenários com incertezas, é oportuna uma análise em torno da temática das ontologias e a averiguação do seu status de pesquisa diante desta problemática.

A proposta desde trabalho é centrada na elaboração de um modelo que dará suporte ao processo de inferência em Redes Fuzzy-Bayesianas. Estas estruturas são derivadas das Redes Bayesianas Clássicas, como formas de representação de conhecimento baseado em informações explicitadas por variáveis e relações probabilísticas.

Ao considerar que estas variáveis probabilísticas, constituintes da estrutura qualitativa de uma Rede Bayesiana, são entidades que especificam conceitos e relações que retratam uma realidade em um domínio, então, é plausível argumentar sobre o fato de que estas estruturas são formas reduzidas de se explicitar uma ontologia existente em nível mais elevado, associado à interpretação do contexto em relevância por parte do modelador.

Sendo assim, é factível considerarmos o estudo das ontologias como pressuposto teórico básico para guiar o desenvolvimento desta pesquisa no que tange à contribuição para o campo das idéias voltadas a construção de estruturas de representação de conhecimento sobre incertezas.

Se uma ontologia descreve as coisas do mundo real sob a forma de especificação de conceitos e relações, é propenso discutir-se sobre o objeto ou entidade que está sendo conceituado na estruturação de uma ontologia em termos de sua caracterização, quantitativa ou qualitativa e, a partir de então analisar se tal conceito em questão é de natureza completa ou não.

O que pretende-se com esta argumentação é elucidar o fato de que as ontologias podem lidar com conceitos e relações sobre domínios que sugerem a existência de variáveis discretas, completas, e também aquelas que denotam subjetividade, vagueza, incompletude ou continuidade. Para exemplificar, suponhamos um processo de classificação envolvendo conceitos de caráter discreto e completo como mostrado na figura 11:

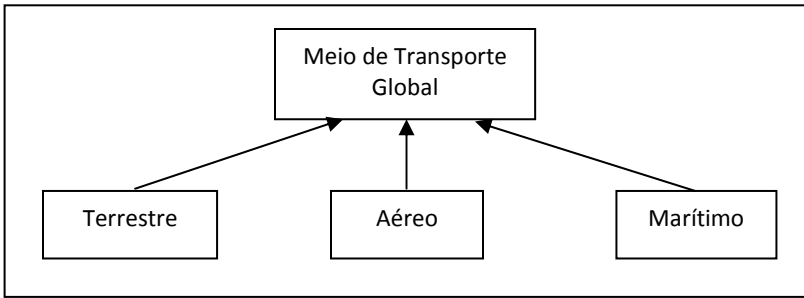


Figura 11 – Exemplo de classificação de natureza completa e discreta
 Fonte: (do autor)

Já no próximo exemplo mostrado pela figura 12 observamos uma classificação envolvendo termos de natureza incompleta e imprecisa, caracterizados pela sua existência em um intervalo de subjetividade e de notação quantitativa contínua.




Figura 12 – Exemplo de classificação de natureza subjetiva
 Fonte: (do autor)

É notável neste caso, que há uma imprecisão intrínseca aos limites dos termos (conceitos) da estrutura de classificação. Também, nota-se uma sobreposição conceitual nestes limites, ou seja, é plausível considerar as intersecções da figura 13:

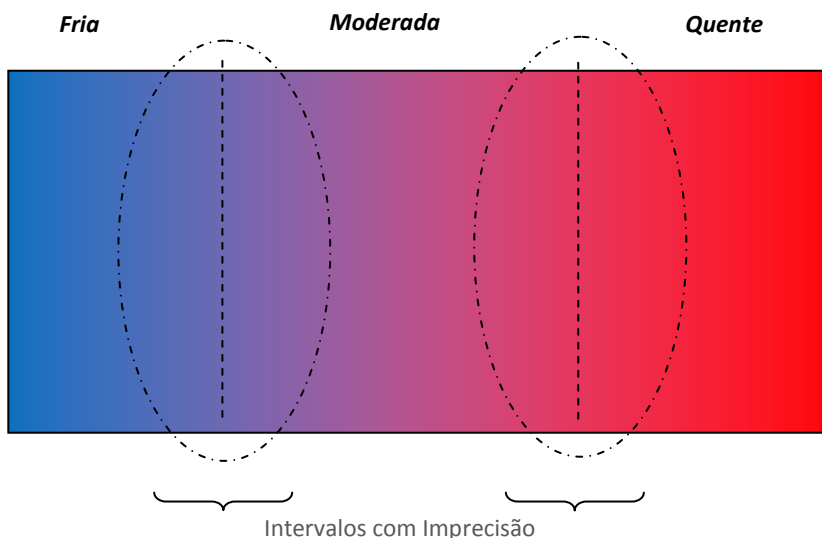


Figura 13 – Sobreposição conceitual pela imprecisão
 Fonte: (do autor)

Esta preocupação em torno do fator imprecisão inerente ao processo de modelagem de ontologias sobre conhecimento incerto é percebido pela elaboração de trabalhos que propuseram uma abordagem difusa a construção deste tipo de conhecimento.

Borges *et al.* (2010) realizaram uma revisão sistemática para conhecer o *status* de pesquisa sobre as Ontologias Fuzzy e verificaram nos trabalhos de Lee, Jian e Huang (2005), Bandini, Calegari e Radaelli (2006), Calegari e Ciucci (2006 e 2008), Calegari e Sanchez (2008) e Zhai *et al.* (2009) acentuado estudo sobre as ontologias fuzzy. Estes autores compartilham da seguinte definição sobre uma ontologia fuzzy “*é uma ontologia estendida com valores fuzzy que são atribuídos a entidades e relações da ontologia*”.

Naturalmente, a imprecisão é um tipo de incerteza manifestada em conceituações especificadas por ontologias e neste caso, têm-se observado o emprego da Lógica Fuzzy como conjunto de técnicas e ferramentas de apoio ao tratamento deste tipo de conhecimento incompleto. Contudo, não é o único tipo de incerteza encontrado quando da especificação de variáveis obtidas a partir de um domínio que se deseje modelar.

Outra forma de incerteza amplamente elucidada em muitas demandas às ontologias, como já citado anteriormente, no caso das

aplicações para a área de medicina, é a aleatoriedade. O conhecimento obtido por informações oriundas da causalidade sugere um tratamento probabilístico ao uso das ontologias.

A abordagem probabilística possui amplo acervo de contribuições científicas para a construção de ontologias sobre domínios de incerteza manifestada pela aleatoriedade.

Para um breve encaminhamento às discussões posteriores sobre a temática da abordagem probabilística em ontologias é oportuno destacar o trabalho de Yang e Calmet (2005) que descrevem sobre a ferramenta *OntoBayes* a qual integra Redes Bayesianas e Ontologias. Também, trabalhos como aqueles desenvolvidos por Ding (2005) e por Carvalho (2008 e 2011) descrevem suas contribuições sobre a inserção de notações probabilísticas na linguagem *OWL* e o surgimento da linguagem *PR-OWL*.

Outros trabalhos envolvem o estudo das incertezas representadas em ontologias e que não utilizam abordagens probabilísticas. A Teoria da Possibilidade também tem sido empregada para solucionar o problema da representação de incertezas. Uma das soluções mais referenciadas na literatura, conforme é encontrado em (Ross, 1995) é a Teoria da Evidência de *Dempster-Shafer*, que utiliza uma modelagem matemática para definir *funções de crença* que medem a intensidade ou força de uma evidência.

Em Nagy, Vargas-Vera e Motta (2006) foi relatada a utilização de *funções de crença* da Teoria de *Dempster-Shafer* para melhorar a exatidão do mapeamento de ontologias através da combinação das semelhanças que foram originalmente criadas por algoritmos de similaridade, sintática e semântica.

Em consonância com a forma de organização deste trabalho e pretendendo-se uma descrição mais detalhada sobre as ontologias probabilísticas e estocásticas não se estenderá esta temática nesta secção, pois será explorada com mais intensidade em secção posterior dada pelos resultados colhidos num estudo de revisão sistemática.

O termo – *incerteza* é amplamente referenciado neste trabalho justificando ser um adjetivo para uma categoria de conhecimento o qual é essencial na motivação da presente investigação. As afirmativas anteriores e ao longo das próximas discussões trazem uma descrição do fator incerteza associando-o às duas formas mais elucidadas pelo objetivo maior desta pesquisa: a incerteza oriunda da *causalidade* e representada por *probabilidades* e a incerteza dada pela existência de *imprecisão*.

É oportuno revisar de que modo o fator imprecisão pode ser categorizado pela teoria e para tal Andrade (2012) contribui apresentando esta categorização da seguinte forma:

- **Indecidibilidade:** uma forma de ambigüidade associada com nossa habilidade de discriminar entre diferentes estados de um evento;
- **Exatidão:** o grau no qual uma medida corresponde ao valor padrão de uma quantidade;
- **Ambigüidade:** uma relação muito estreita ao conceito de *nebulosidade*. O autor descreve que, em Lógica Fuzzy, ambigüidade aparece na hora em que uma variável pode “*ser duas coisas*” ao mesmo tempo;
- **Vaguidade:** ser vago é ser incerto, indefinido, confuso, misturado. Estes são conceitos intimamente ligados a *nebulosidade* e referem-se à falta de nitidez. Andrade (2012) afirma ainda que: “*A Teoria da Possibilidade atua como métrica da vaguidade*”.

Conforme já apresentado no início deste trabalho, o cenário da Classificação de Risco Metabólico em crianças e adolescentes provê variáveis de natureza probabilísticas para descrever e representar o conhecimento inerente ao domínio, contudo, identifica-se a imprecisão existente nos estados que constituem as variáveis de entrada ou evidências apresentadas à Rede Bayesiana.

Considerando os postulados de Zadeh (1965) e observando como Römer e Kandel (1995) interpreta o conceito de imprecisão e recorre a Lógica Fuzzy para representá-lo é notável que a imprecisão a ser considerada no desenvolvimento do modelo de inferência desta investigação parece estar mais associada à ambigüidade e vaguidade. Contudo, esta “*mistura*”, assim descrita por Andrade (2012) pode implicar numa complexa especificação de conceitos ou termos lingüísticos que definirão a forma de representação das variáveis que denotam imprecisão no domínio. Para tal situação diante da complexidade desta representação será recorrido ao argumento da *Superposição de Estados*.

2.5 Redes Bayesianas

2.5.1 O conhecimento representado por probabilidade

Na atividade de modelagem, o engenheiro do conhecimento pode lidar com inúmeros tipos de informação extraídos das mais variadas fontes, desde aquelas encontradas sobre uma forma explicitada, por meio de bases de dados estruturadas ou não, até aquelas obtidas por meio da externalização

de conhecimento implícito de indivíduos ou oriundos de alguma prática coletiva.

Este conhecimento, em sua fonte primitiva, pode ser obtido a partir de fatos descritivos, de regras aplicadas a um processo, sentenças proposicionais e pode ser do tipo declarativo, *procedural*, baseado em senso comum ou heurístico.

Hayes-Roth, Waterman e Lenat (1983) afirmam: “*o conhecimento consiste em descrições simbólicas que caracterizam os relacionamentos empíricos e definicionais em um domínio e os procedimentos para manipulação dessas descrições*”.

Em certos domínios, o tipo de conhecimento explorado pelo engenheiro é de natureza incerta, incompleta e pode ser baseado na subjetividade, na crença, na dualidade, na sobreposição conceitual, na imprecisão ou vagueza.

Sobre um espectro mais epistemológico das questões associadas ao conhecimento diante de incertezas, se faz necessária uma análise da nossa interpretação do que vem a ser uma incerteza manifestada a partir de uma observação por meio do desenvolvimento do pensamento complexo (MORIN, 2006).

A incerteza, como um conhecimento causal é sugestiva de ser representada por probabilidades (PEARL, 1988). Devido ao suporte matemático consolidado pela Teoria da Probabilidade é possível construir um Sistema de Conhecimento utilizando as técnicas probabilísticas, para representar, relacionar e inferir sobre variáveis aleatórias.

Na conjuntura dos Sistemas Especialistas, medidas de probabilidade refletem a crença do especialista sobre o que ele espera que ocorra em situações similares àquelas que têm experienciado e aprendido ao longo de sua vivência. Isto é, o especialista está tentando extrapolar com base em sua experiência e aprendizado no domínio de aplicação (NASSAR, 2012).

Medidas de probabilidade, crença e plausibilidade são formas de se expressar e manipular valores interpretados como incerteza. Este tratamento estocástico da informação ou do conhecimento é categorizado por uma das Escolas Formais, denominada de *Neo-probabilística*, assim abordado por Pearl (1988).

2.5.2 Definições formais de probabilidade

Seja ε um conjunto finito e P uma função de ε para os números reais não negativos, tal que:

$$\sum P(e) = 1 \quad \forall e: e \in \mathcal{E}$$

O par (\mathcal{E}, P) é chamado de espaço de probabilidade. Os elementos de \mathcal{E} são chamados de eventos simples ou elementares. P é chamado de função de densidade de probabilidade ou função de probabilidade. Desta definição resulta que a probabilidade de qualquer evento e , denotada por $P(e)$, é medida por um número $\in [0,1]$. Intuitivamente, \mathcal{E} é a coleção de resultados esperados em um domínio de aplicação. O valor de $P(e)$ é uma estimativa da crença à ocorrência do resultado e (NASSAR, 2012).

2.5.2.1 Axiomas e Propriedades

O desenvolvimento de abordagens que modifiquem os esquemas primitivos da Teoria da Probabilidade em mecanismos de apoio ao raciocínio e representação de conhecimento sobre incertezas requer atenção a determinadas premissas básicas que asseguram algum grau de acurácia ao modelo derivado. Estas premissas são:

- a) $0 \leq P(A) \leq 1$
- b) $P(\mathcal{E}) = 1$
- c) $P(A \cup B) = P(A) + P(B)$, se A e B forem eventos disjuntos
- d) Se $A \subseteq B \subseteq \mathcal{E}$ então $0 \leq P(A) \leq P(B) \leq 1$
- e) Se $A, B \subseteq \mathcal{E}$ então $P(A \cap B) + P(A \cap \bar{B}) = P(A)$ e $P(A \cup B) = P(A) + P(B) - P(A \cap B)$
- f) $P(A) + P(\bar{A}) = 1$
- g) Se $A_i \subseteq \mathcal{E}$ para $1 \leq i \leq n$ e $A_i \cap A_j = \emptyset$ então $\forall i \neq j \quad P(A_1 \cup A_2 \cup \dots \cup A_n) = P(A_1) + P(A_2) + \dots + P(A_n)$

2.5.2.2 Probabilidade Condicional

Este conceito e recurso primitivo fornecido pela Teoria da Probabilidade é de importância fundamental para a solidez matemática que permite a modelagem de mecanismos de inferência aplicados em situações em que o raciocinador deve considerar o fator probabilístico como medida de certeza no espectro das relações estabelecidas entre múltiplas variáveis aleatórias.

Ao denotarmos $P(B/A)$ significa estarmos obtendo a probabilidade da ocorrência do evento B dada à ocorrência do evento A . Logo, estaremos calculando $P(B)$ no espaço amostral reduzido de A (MEYER, 2000).

Reportando-se ao conceito de *Frequência Relativa*, conforme retratado em (Goldman, 1990) é possível obter-se a probabilidade condicional entre dois eventos A e B a partir da aplicação da seguinte equação:

$$P(B/A) = \frac{P(A \cap B)}{P(A)} \quad \text{Eq. (1)}$$

desde que $P(A) > 0$.

A partir da especificação da equação (1) é oportuno elucidar o Teorema da Multiplicação:

Teorema: *a probabilidade de dois eventos ocorrerem simultaneamente é o produto da probabilidade de um deles pela probabilidade do outro dado que o primeiro ocorreu* (CHARNIAK, 1991). O teorema é apresentado pela equação (2):

$$P(A \cap B) = P(B/A) \cdot P(A) \quad \text{Eq. (2)}$$

2.5.3 Raciocínio Bayesiano

O *raciocínio bayesiano* é o mecanismo básico de inferência utilizado pelas Redes Bayesianas no processo de recuperação do conhecimento a partir das relações de dependência entre variáveis aleatórias.

Conforme será mostrado em capítulo posterior, a essência desta pesquisa perpassa por uma modificação no esquema formal do raciocínio bayesiano clássico de modo a permitir que seja relevado o tratamento probabilístico sobre um cenário de variáveis caracterizadas por imprecisão.

Na sequência será apresentado o formalismo que define a equação básica do raciocínio bayesiano clássico.

Teorema: Seja uma partição de um espaço amostral S , conjunto de eventos $A_1, A_2, A_3, \dots, A_n$, os eventos A_i são mutuamente exclusivos e S é o seu conjunto União. Considerando agora outro evento B cuja probabilidade $P(B) > 0$ temos:

$$B = S \cap B = (A_1 \cup A_2 \cup \dots \cup A_n) \cap B \quad \text{Eq. (3)}$$

onde A_i e B são mutuamente exclusivos. Desta forma a probabilidade da ocorrência de B é dada por:

$$P(B) = P(A_1 \cap B) + P(A_2 \cap B) + \dots + P(A_n \cap B) = \sum_i P(A_i \cap B) \quad \text{Eq. (4)}$$

Aplicando o Teorema da Multiplicação, da equação (2) teremos:

$$P(B) = \sum_i P(A_i \cap B) = \sum_i P(B|A_i) \cdot P(A_i) \quad \text{Eq. (5)}$$

ainda denotado por

$$P(A_i \cap B) = P(B|A_i) \cdot P(A_i) = P(A_i) \cdot P(B) \quad \text{Eq. (6)}$$

A partir da resolução desta última equação obtem-se a formulação para o Teorema de Bayes:

$$P(A_i|B) = \frac{P(B|A_i) \cdot P(A_i)}{P(B)} = \frac{P(B|A_i) \cdot P(A_i)}{\sum_i P(B|A_i) \cdot P(A_i)} \quad \text{Eq. (7)}$$

Na obra de Lipschutz (1993) é apresentada a definição formal do Teorema de Bayes.

Teorema: Suponha $A_1, A_2, A_3, \dots, A_n$ ser uma partição de S em B , um evento qualquer. Logo, $\forall i$

$$P(A_i|B) = \frac{P(B|A_i) \cdot P(A_i)}{P(B)} = \frac{P(B|A_i) \cdot P(A_i)}{\sum_i P(B|A_i) \cdot P(A_i)} \quad \text{Eq. (8)}$$

Conforme concluído por (Paulino; Turkman; Murteira, 2003), o Teorema de Bayes é uma das contribuições da Matemática no campo da aprendizagem baseada na experiência. Isso se deve ao fato da modificação

de uma atitude inicial em relação a possíveis causas após se ter a informação adicional de que determinado acontecimento ocorreu.

2.5.4 Redes Bayesianas e o processo de classificação

As Redes Bayesianas, também conhecidas como Redes de Probabilidade ou Redes de Crença são estruturas representadas por diagramas fundamentados pela Teoria dos Grafos que fornecem uma maneira de representar o conhecimento sob a forma da especificação de variáveis aleatórias e de relações estabelecidas entre estas variáveis.

O conhecimento implicitamente armazenado nos *nodos* do grafo da Rede Bayesiana pode ser denotado por meio de valores de probabilidade, com números reais compreendidos no intervalo $[0,1]$ ou por meio de regras que descrevem a relação causal entre as variáveis envolvidas no domínio.

O processo de criação de uma Rede Bayesiana, bem como da realização de inferência sobre a mesma pode ser simples, no entanto, dependendo do número de variáveis envolvidas no modelo todo este panorama pode se tornar exponencialmente complexo. Existem diversos algoritmos voltados a atividade de *aprendizado* e de *atualização* de uma Rede Bayesiana (RUSSEL e NORVIG, 1995).

O propósito desta unidade é descrever as características básicas de representação de conhecimento por meio das Redes Bayesianas. Não faz parte da essência dos objetivos desta pesquisa uma investigação exaustiva acerca da complexidade e da completude computacional envolvida na implementação de Redes Bayesianas ou suas formas híbridas. Esta problemática sugere pesquisas no campo das Ciências da Computação e da Matemática Computacional.

2.5.4.1 Aspectos Estruturais das Redes Bayesianas

Conforme descrito em (Marques; Dutra, 2008) uma Rede Bayesiana consiste das seguintes características:

- Um conjunto de variáveis e um conjunto de arcos associados a estas variáveis;
- Cada variável possui um número finito de estados mutuamente exclusivos;
- Variáveis e arcos formam um Grafo Dirigido Acíclico (*DAG*);
- Para cada variável A que possui como pais B_1, \dots, B_n existe uma *Tabela de Probabilidades Condicionais (CPT)*, que fornece $P(A|B_1 \cap \dots \cap B_n)$.

Para Neapolitan (2003) uma Rede Bayesiana é a representação correta de um domínio caso a *condição de Markov* seja satisfeita. Na mesma obra o autor define:

Definição (Condição de Markov): Suponha a distribuição de probabilidade conjunta das variáveis aleatórias em um conjunto de *nodos* V em um *DAG* $G = (V, E)$. Então dizemos que (G, P) satisfazem a *condição de Markov* se cada variável $X \in V$, X é condicionalmente independente dos *nodos* não descendentes dados seus pais.

É notável que a Teoria da Probabilidade provê consistência às Redes Bayesianas sendo adequada para representar o raciocínio humano sobre “o acaso”. Isso se deve ao fato dos seres humanos não trabalharem com grandes quantidades de proposições. Quando este conjunto se torna amplo então o processo de tomada de decisão torna-se complexo. A representação gráfica inerente a especificação das Redes Bayesianas pode trabalhar localmente o conceito de dependência, aproximando-se desta forma, a maneira que ocorre o raciocínio humano a causalidade (PEARL, 1988).

A composição da parte estrutural da Rede Bayesiana reflete as relações causais entre as variáveis e os valores de probabilidade que denotam a força desta relação. De uma forma geral, a estrutura de uma Rede Bayesiana é dada por:

- 1 **Parte Qualitativa:** é a representação gráfica por meio de um *DAG* cujas variáveis são os *nodos* e os arcos direcionados representam as relações de dependência entre as variáveis;
- 2 **Parte Quantitativa:** é o conjunto das probabilidades condicionais associadas aos arcos existentes no modelo gráfico e as probabilidades estimadas à priori das variáveis independentes (variáveis de saída da Rede).

Os *nodos* de uma Rede Bayesiana podem estar dispostos e conectados de modo a defini-la em uma estrutura denominada hierárquica, onde as relações de dependência são mais complexas. Esta proposta discorre sobre a utilização de uma estrutura simplificada de representação de uma Rede Bayesiana, apropriada a processos de classificação, conhecida como estrutura *Naive Bayes* (SAHAMI, 1996).

Ao passo em que a topologia da Rede Bayesiana é definida, a sequência é especificar as probabilidades condicionais dos *nodos* que possuem dependências diretas e utilizar o mecanismo de inferência

bayesiana para obter novos valores de probabilidade, como sendo um novo conhecimento produzido.

Segundo Pearl (1988) a Rede Bayesiana pode ser considerada uma base de conhecimento abstrata que contém uma grande variedade de composições diferentes, pois representa a estrutura geral dos processos causais do domínio em lugar de qualquer detalhe da população de indivíduos. A vantagem desta representação é que permite ao especialista expressar diretamente a relação qualitativa fundamental de “dependência direta” entre as variáveis.

No desenvolvimento de uma Rede Bayesiana, o direcionamento das setas é essencial para exibir as dependências de não-transitividade. Dois eventos não chegam a ser relevantes entre si somente pelo fato de predizerem uma consequência comum, mas tornam-se relevantes quando esta consequência é realmente observada. Se os arcos forem despojados das setas, algumas dessas relações não serão representadas.

Exibindo as irrelevantâncias do domínio, o raciocínio causal minimiza o número de relações que precisam ser consideradas na construção do modelo e em muitas das conclusões futuras. Sobre este aspecto, Pearl (1988) discorre que a codificação de um conhecimento por meio de regras e evidências, uma prática prevalecente dos Sistemas Especialistas baseados em regras, falha neste ponto. Ao tentar representar todas as exceções de um domínio, o número de regras torna-se exaustivo e intratável. Assim sendo, o mecanismo de raciocínio bayesiano, apoiado pela Teoria da Probabilidade, em termos de praticidade na manipulação numérica de valores de probabilidade, torna-se imensamente mais propício para dar suporte ao processamento do conhecimento nas Redes Bayesianas.

Seguindo com uma abordagem sobre a forma de representação do conhecimento e das relações existentes entre variáveis em um domínio descrito pela causalidade, recorreremos ao exemplo relatado em (Russel e Norvig, 1995):

Exemplo: *Um alarme está sendo instalado e mesmo sendo confiável na detecção de assaltos, ele pode disparar também devido a um terremoto. Dois vizinhos, João e Maria se disponibilizaram a telefonar caso o alarme dispare. João sempre liga quando ouve o alarme, contudo, em algumas vezes ele confunde o alarme com o telefone e também avisa. Maria, por sua vez, gosta de ouvir música alta e às vezes não ouve o alarme disparar e não avisa.*

O grafo resultante da descrição do problema é dado pela figura 14:

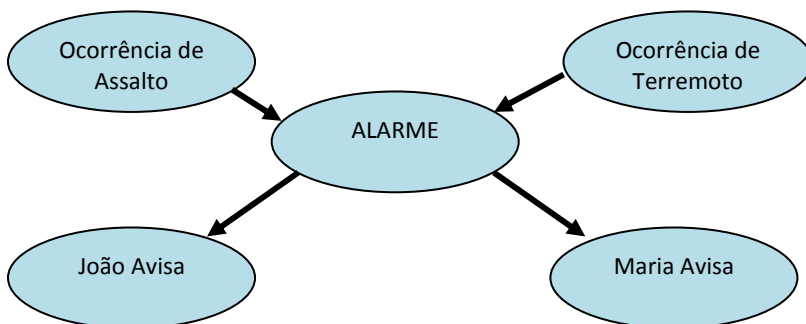


Figura 14 – Grafo de representação do problema do Alarme
Fonte: Adaptado de Russel e Norvig (1995)

Definida a topologia da rede será necessário fornecer os valores à sua *Parte Quantitativa* que especificará as probabilidades condicionais para cada variável (*nodo*) dado seus pais que são seus predecessores imediatos. As tabelas, 2 e 3 mostram as *CPTs* (*Tabelas de Probabilidades Condicionais*) que explicitam o conhecimento das relações causais entre as variáveis do problema descrito.

A partir do exemplo retratado por Russel e Norvig (1995), Marques e Dutra (2008) descrevem fatos ou relações que não estão sendo expressas na representação, contudo, são condições implícitas diante da incerteza presente em alguns arcos. O autor afirma ser um trabalho dispendioso e até mesmo impossível e que um sistema bayesiano pode calcular um grande número de probabilidades, mesmo que de forma aproximada.

Marques e Dutra (2008) descrevem que, para os *nodos* que não possuem *pai*, no caso, *Assalto* e *Terremoto*, as probabilidades incondicionais são atribuídas por especialista ou por meio de tratamento estatístico que forneça as estimativas mais fidedignas possíveis sobre as variáveis e relações no domínio tratado.

Tabela 2 - CPT da variável *Alarme*

Assalto	Terremoto	$P(\text{Alarme} \text{Assalto} \wedge \text{Terremoto})$ (%)	
		SIM	NÃO
SIM	SIM	95	5
SIM	NÃO	95	5
NÃO	SIM	29	71
NÃO	NÃO	0,1	99,9

Fonte: Adaptado de Marques e Dutra (2008)

Tabela 3 - CPTs das variáveis *JoãoAvisa* e *MariaAvisa*

<i>JoãoAvisa</i>	$P(\text{JoãoAvisa} \text{AlarmeDisparou})$ (%)	<i>MariaAvisa</i>	$P(\text{MariaAvisa} \text{AlarmeDisparou})$ (%)
SIM	90	SIM	70
NÃO	5	NÃO	1

Fonte: Adaptado de Marques e Dutra (2008)

Com estas tabelas é possível realizar inferências sobre a Rede Bayesiana obtendo-se assim novos conhecimentos produzidos a partir de incertezas implícitas nas relações dispostas pelos arcos.

Para exemplificar o processo de produção de novos conhecimentos a partir da inferência bayesiana aplicaremos o exemplo citado em (Russel e Norvig, 1995) utilizando o software *Netica*, uma *shell* com distribuição em versão limitada pela *Netica Norsys* (Netica, 2012) e que utilizaremos nas demonstrações futuras. A figura 15 mostra a Rede Bayesiana do problema do *Alarme* implementada no software *Netica*:

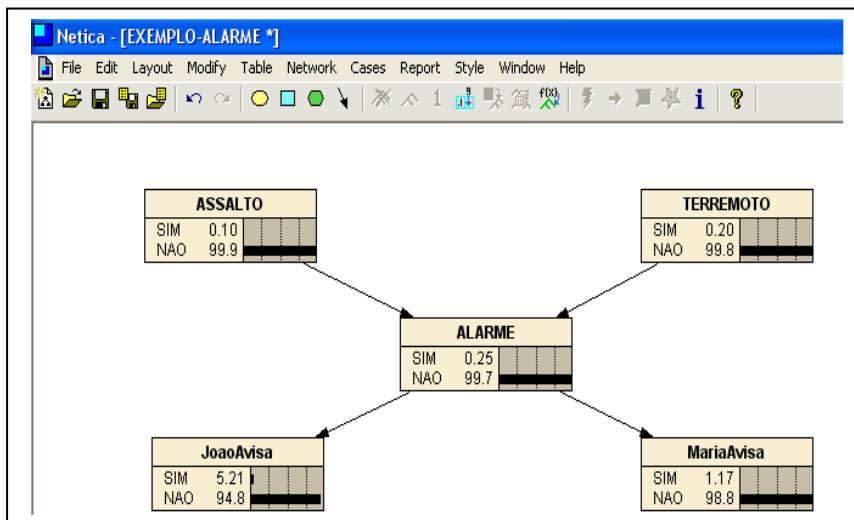


Figura 15 – Rede Bayesiana do problema do Alarme no Shell Netica Norsys
Fonte: (do autor)

2.5.4.2 Processo de Distribuição de Probabilidade Conjunta

A partir do momento que a Rede Bayesiana possui o conhecimento armazenado acerca das probabilidades condicionais contidas nas tabelas (CPTs) é possível obter-se a *distribuição de probabilidade conjunta* sobre todo o domínio em termos das relações entre as variáveis aleatórias.

Considere X_i como sendo um nodo da rede e $pa(X_i)$ denotando os seus pais. Assim, X_1, X_2, \dots, X_n são todos os nodos do domínio em questão e $P(X_1, X_2, \dots, X_n)$ é a *distribuição de probabilidade conjunta* da Rede Bayesiana. O cálculo da *distribuição de probabilidade conjunta* é suportado pelo seguinte teorema:

Teorema: *Se uma Rede Bayesiana satisfaz a Condição de Markov, então a distribuição de probabilidade conjunta é igual ao produto das probabilidades condicionais de todos os nodos dado os valores dos seus pais.*

$$P(X_1, X_2, \dots, X_n) = \prod_{i=1}^n P(X_i | pa(X_i)) \quad \text{Eq. (9)}$$

Os valores de probabilidade armazenados agora na estrutura da Rede permitem a realização de consultas especializadas obtidas pelo raciocinador bayesiano (RUSSEL e NORVIG, 1995).

Para exemplificar, retomamos a figura 15 e observamos o valor 0,25% associado ao estado SIM da variável ALARME. Logo, este valor corresponde a probabilidade do ALARME disparar segundo a distribuição conjunta da Rede em suas relações com os os *nodos* pais – ASSALTO e TERREMOTO. Denotaremos $P(\text{ALARME})$ com estado = SIM simplesmente por $P(\text{ALARME})$. O valor foi obtido pela aplicação da equação (9) na forma:

$$P(\text{alarme}) = P(\text{alarme}|\text{assalto} \wedge \text{terremoto}) * P(\text{assalto}) * P(\text{terremoto}) + P(\text{alarme}|\text{assalto} \wedge \neg \text{terremoto}) * P(\text{assalto}) * P(\neg \text{terremoto}) + P(\text{alarme}|\neg \text{assalto} \wedge \text{terremoto}) * P(\neg \text{assalto}) * P(\text{terremoto}) + P(\text{alarme}|\neg \text{assalto} \wedge \neg \text{terremoto}) * P(\neg \text{assalto}) * P(\neg \text{terremoto})$$

∴

$$P(\text{alarme}) = (95\% * 0,1\% * 0,2\%) + (95\% * 0,1\% * 99,8\%) + (29\% * 99,9\% * 0,2\%) + (0,1\% * 99,9\% * 99,8\%) = \boxed{0,25\%}$$

Para um segundo exemplo, suponhamos a situação ilustrada pela figura 16. Nesta, queremos demonstrar o processo de raciocínio bayesiano que resultou o valor de 76,1% como sendo a probabilidade do ALARME disparar confirmado o fato que João avisou e que Maria não avisou, reportando ao caso exemplo citado anteriormente.

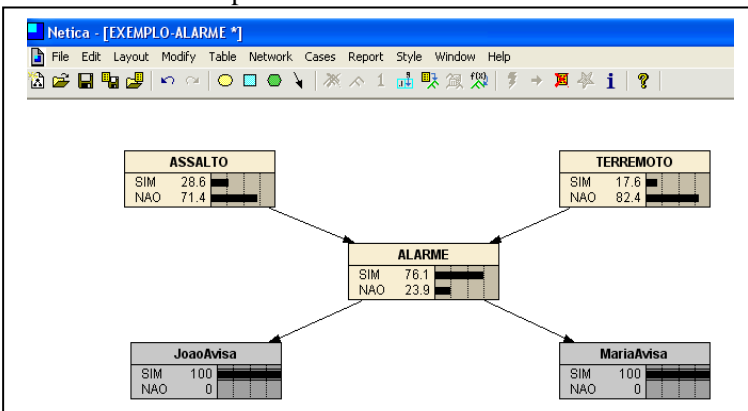


Figura 16 – Simulação de inferência – problema do Alarme
 Fonte: (do autor)

A formulação para a condição ilustrada acima é dada por:

$$P(\text{alarme}|\text{JoaoAvisa} \cap \text{MariaAvisa}) = \frac{P(\text{JoaoAvisa}|\text{alarme}) * P(\text{MariaAvisa}|\text{alarme}) * P(\text{alarme})}{P(\text{JoaoAvisa} \cap \text{MariaAvisa})}$$

Note que esta formulação está em conformidade com o enunciado do Teorema de Bayes da equação (7). Agora, desmembramos o denominador da razão acima:

$$P(\text{JoaoAvisa} \cap \text{MariaAvisa}) = P(\text{JoaoAvisa}|\text{alarme}) * P(\text{MariaAvisa}|\text{alarme}) * P(\text{alarme}) + P(\text{JoaoAvisa}|\neg\text{alarme}) * P(\text{MariaAvisa}|\neg\text{alarme}) * P(\neg\text{alarme})$$

Podemos observar que o processo de inferência bayesiana é recursivo, ou seja, o raciocinador deve-se reportar ao valor de $P(\text{alarme})$ sendo que esta variável é dependente de seus pais, os *nodos ASSALTO e TERREMOTO*. O cálculo de $P(\text{alarme})$ já foi realizado no exemplo anterior. Contudo, para obter a probabilidade $P(\neg\text{alarme})$ basta aplicar o axioma (f) elucidado anteriormente.

Com estas considerações e especificações podemos seguir com a demonstração do cálculo:

$$P(\text{alarme}|\text{JoaoAvisa} \cap \text{MariaAvisa}) = \frac{90\% * 70\% * 0,25\%}{(90\% * 70\% * 0,25\%) + (5\% * 1\% * 99,75\%)} \approx 76\%$$

Nota: pequenas diferenças foram verificadas nos cálculos de simulação. Isso se deve ao fato dos critérios de truncamento e arredondamento utilizados pelo software *Netica* influenciarem na precisão dos valores finais.

2.5.5 Limitações das Redes Bayesianas diante da imprecisão

O exemplo do problema do ALARME demonstra uma típica aplicação em que as Redes Bayesianas Clássicas e o raciocínio bayesiano é eficaz em processo de classificação no que refere-se ao apontamento das hipóteses (saída). Isso é plausível ao observarmos que os estados das variáveis probabilísticas são de natureza discreta e bivalente.

Entretanto, observe a Rede Bayesiana ilustrada na figura 17 a seguir:

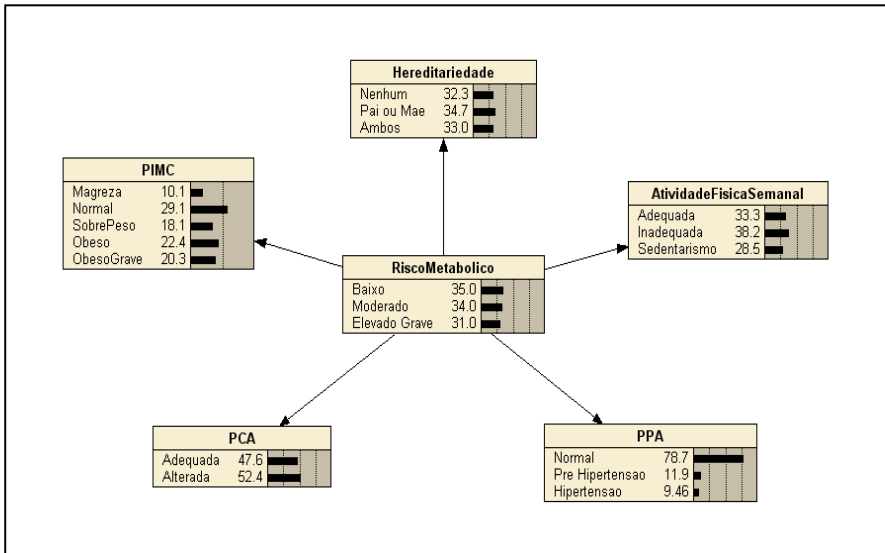


Figura 17 – Rede Bayesiana para Diagnóstico de Risco Metabólico

Fonte: Nassar (2012)

Os estados que constituem as variáveis probabilísticas de entrada da Rede Bayesiana, embora, especificados e tratados como estados discretos, denotam subjetividade, se considerarmos sua inserção num contexto de domínio real. Por exemplo, observamos a especificação dos estados da variável *PIMC* (representada pelo *Percentil do Índice de Massa Corpórea, em crianças e adolescentes*). *Magreza*, *Normal*, *SobrePeso*, *Obeso* e *ObesoGrave* estão associados a conceitos subjetivos, imprecisos e até mesmo sugerem sobreposição entre os mesmos.

Esta especificação propõe de certo modo uma indagação: *qual o grau de influência sobre o raciocínio plausível e a significância da informação que gera um novo conhecimento se considerarmos um indivíduo com valores ou medidas aferidas de modo a ficar no estado – SobrePeso e deste passar para o estado – Obeso?*

Conforme os pressupostos da Teoria da Possibilidade, segundo Ross (1995), termos subjetivos ou linguísticos como estes descritos no exemplo da Rede Bayesiana da figura 17 possuem uma característica natural de sobreposição ou intersecção.

O método de inferência bayesiano clássico não releva o fator imprecisão existente no domínio e, de acordo com a argumentação

realizada no trabalho de Mayer (2012), este tipo de raciocínio plausível sobre imprecisão acarreta em classificações equivocadas, não conferindo de modo correlato ou similar aos resultados mais realistas do ponto de vista daqueles obtidos pelo raciocínio aproximado do especialista humano.

No caso da Rede Bayesiana da figura 17, que foi simulada por Mayer (2012), uma mudança na confirmação das evidências representadas pelos estados da variável *PIMC*, por exemplo, de *SobrePeso* para *Obeso* ou de *Obeso* para *ObesoGrave* implica em mudanças abruptas na classificação da saída representada pela variável *RiscoMetabólico* em termos de valores de probabilidade. Segundo Mayer (2012), classificações nos limítrofes interferem no diagnóstico final.

Conhecido o fato de que o método de inferência bayesiano pode ser ineficaz em classificações realizadas em um domínio que, não somente é modelado por variáveis probabilísticas, mas que possui variáveis linguísticas oriundas de conceitos vagos, imprecisos ou sobrepostos, é pertinente investigarmos abordagens híbridas no campo do tratamento estocástico do conhecimento.

Para tal, na sequência deste trabalho será realizada uma revisão sobre a Teoria da Possibilidade, especificamente, retratando a Lógica Fuzzy como solução para a modelagem de variáveis linguísticas de domínios com imprecisão. O objetivo é convergir para um segmento de pesquisa que descreve formas híbridas de tratar conhecimento sobre incertezas, e, mais especificamente, com o propósito de preencher lacunas no campo do estudo das Redes Fuzzy-Bayesianas.

2.6 Lógica Fuzzy e o raciocínio heurístico

O objetivo desta unidade é descrever os princípios essenciais da Lógica Fuzzy e sua aplicabilidade ao tratamento estocástico da informação e do conhecimento.

O estudo da Lógica Fuzzy, também conhecida por Lógica Nebulosa pode ser realizado sobre várias perspectivas, tais como, filosófica, matemática, cognitiva e associada diretamente a modelagem de inúmeras aplicações em Computação, Engenharia, Economia, Medicina etc.

Como segmento no campo da Lógica, pode ser considerada como um tipo de Lógica Paraconsistente, contradizendo alguns princípios básicos da Lógica Clássica Aristotélica, considerando informações de natureza incompleta, inconsistente (ABE, 1992).

A Lógica Fuzzy tem sido empregada de uma maneira bastante acentuada em aplicações industriais, tais como, em robótica. A modelagem

de aplicações que envolvem fenômenos complexos e dinâmicos, muitas vezes, torna-se simplificada devido a forma em que são realizadas as operações definidas pela Lógica Fuzzy. Segundo (Barros, 1997), quando o fenômeno estudado apresenta subjetividade como forma de imprecisão, a melhor forma de olhar o problema é por meio da Teoria Fuzzy.

Por ser referenciada como ferramenta de Inteligência Artificial, a Lógica Fuzzy é utilizada na modelagem de sistemas que emulam comportamento inteligente humano no que tange ao aspecto da inferência ou raciocínio aproximado (heurístico) sobre informação incompleta (MAMDANI, 1981).

As discussões que se propõe neste trabalho enfatizam o termo *imprecisão* como uma característica de incerteza manifestada em domínios. Este é o motivo que nos faz reportar aos recursos da Lógica Fuzzy para a modelagem de incerteza.

Suleman (2009) explora o conceito de *Partição Difusa*, que permite relativizar a heterogeneidade individual, observadas em dados mistos, posicionando cada indivíduo em função da sua distância ao que ele determina ser uma estrutura de perfis. Para o autor, esta partição é construída por meio de um mecanismo de compensação, ou seja: “*uma maior pertença a um dos perfis implica em uma menor pertença aos outros*”.

Em Ross (1995) é encontrada uma rica abordagem matemática e descritiva sobre os elementos e processos que constituem uma modelagem de sistema baseado em Lógica Fuzzy. O autor insere a abordagem fuzzy no contexto das ferramentas da *Teoria da Possibilidade* e discorre formas de integração com outras técnicas para tratamento estocástico de informação, tais como, a Teoria da Evidência e o estudo da probabilidade.

Zadeh (1978) propôs os postulados básicos que integram os princípios da Lógica Fuzzy e em sua obra, na qual discorre sobre a Teoria da Possibilidade, o autor apresenta os elementos e processos envolvidos na representação de sistemas fuzzy.

Apesar deste trabalho propor uma revisão em busca da solução da Lógica Fuzzy para o tratamento da imprecisão, não será necessário que esta exploração seja exaustiva em analisar todas as etapas da modelagem fuzzy para soluções. A figura 18 mostra um diagrama das etapas do processamento difuso sobre a informação incompleta:

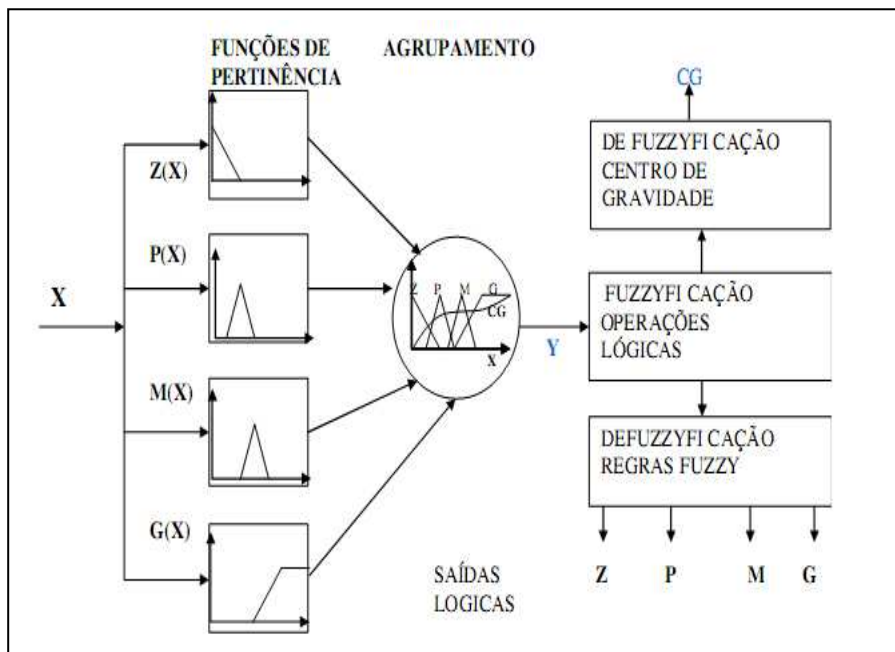


Figura 18 – Sistema Fuzzy Genérico

Fonte: Cavalcanti *et al.* (2012)

Importamo-nos em saber reconhecer de que maneira a imprecisão é percebida num conjunto de variáveis que expressam as entidades e relações em um domínio e como representá-las na forma linguística. Também, verificar como estas variáveis são representadas em termos numéricos e como ocorre o processo de inferência fuzzy que fornecerá os resultados destinados ao propósito maior desta pesquisa na integração com o raciocínio bayesiano.

Em relação a figura 18, será necessário utilizar somente as etapas de entrada, a modelagem das funções de pertinência e o processo de *fuzzificação* das entradas. Não estenderá para as etapas de composição (agrupamento) e defuzzificação das saídas.

2.6.1 Probabilidade versus Possibilidade

Medidas de possibilidade e medidas de probabilidade são formas alternativas para a expressão da incerteza associada a um domínio. Segundo Ross (1995), “*uma medida fuzzy descreve a vagueza ou*

imprecisão na associação de um elemento x a dois ou mais conjuntos Crisp”.

Andrade (2012) define *CRISP* como: “*categórico, taxativo, concreto, nítido, objetivo*”, em contradição a *FUZZY* como sendo: “*nebuloso, difuso, subjetivo, vago, inexato*”.

Uma medida *fuzzy* é a forma de expressão de incerteza considerada pela Teoria da Possibilidade como alternativa para a Teoria da Probabilidade (ZADEH, 1978).

Para exemplificar a diferença entre *probabilidade* e *possibilidade* propõe-se um cenário simplificado:

Considere uma pizza que foi pré-fatiada em 8 pedaços de igual tamanho. Logo, se a totalidade da pizza constitui um universo U , formulamos duas perguntas com teor diferenciado:

*1ª. Suponha que a pizza está fria e deverá ser levada ao microondas para aquecimento. Sabe-se, a priori, que apenas 2 fatias, escolhidas aleatoriamente, serão aquecidas. Sob esta perspectiva, queremos saber – **qual a probabilidade (chance) de alguém consumir uma fatia de pizza que foi aquecida?***

Resposta: $\frac{2}{8} = 25\%$

Portanto, 25% é uma medida de probabilidade como sendo uma expressão de causalidade ou a chance que uma pessoa irá se beneficiar de uma fatia de pizza aquecida.

2ª. Agora, suponhamos que toda as fatias de pizza foram levadas ao microondas e aquecidas por tempos diferentes, ou seja, teremos algumas fatias mais quentes do que outras. Sob esta perspectiva, qual a probabilidade de alguém consumir uma fatia quente?

Resposta: sabemos neste caso que todas as fatias foram aquecidas, logo, do ponto de vista de uma medida de probabilidade a resposta é 100%. Contudo, neste aspecto podemos pensar também numa *medida de possibilidade* de uma pessoa consumir fatias de pizza quente. Para tal, se for possível aferir a temperatura de cada fatia de pizza após retirá-la do microondas, então podemos expressar uma medida de possibilidade – *pizza_quente* num intervalo $\in [0,1]$.

Na perspectiva da Lógica Fuzzy, *pizza_quente* é um conceito subjetivo devido a sua imprecisão. Como as fatias de pizza foram aquecidas em tempos diferentes consequentemente, cada fatia possui uma medida entre $[0,1]$ que expressa a sua possibilidade de ser uma fatia de *pizza_quente*.

Pelas notações em Lógica Fuzzy poderíamos expressar a resposta a 2ª. pergunta da seguinte maneira:

$$\mu(\text{fatia_pizza}_{(i)}) = p \in [0,1] \quad (\forall i=1..8)$$

pizza_quente

Lê-se: p é o grau de pertinência da *fatia_pizza* em relação ao conjunto fuzzy *pizza_quente*.

Notório o fato de que uma medida de probabilidade, associada a aleatoriedade e uma medida de possibilidade fuzzy na forma normalizada, associada ao fator imprecisão são ambas compreendidas no mesmo intervalo [0,1].

A seguir analisar-se-á como a Lógica Fuzzy permite expressar a imprecisão e o modo em que ocorre a inferência sobre a imprecisão.

2.6.2 Conjuntos Clássicos e Conjuntos Fuzzy

Para compreender a aplicabilidade e a funcionalidade da Lógica Fuzzy é necessário em princípio saber distinguir um Conjunto Clássico de um Conjunto Fuzzy e a diferença entre um tipo de relação de pertinência total e outra, gradual.

Ross (1995) define:

“Um conjunto clássico é uma coleção de elementos com as mesmas características inseridos num universo de discurso X . As características dos elementos de X podem ser discreta, valores inteiros contáveis ou valores contínuos em termos de intervalos reais”.

Cada elemento x possui em *relação de pertinência total* ao conjunto X . Suponha um conjunto $X = \{\text{inteiros entre } -5 \text{ e } +5\}$, então sabemos que o elemento $2 \in X$ e que o elemento $7 \notin X$.

Conjuntos fuzzy denotam características subjetivas, onde a vagueza e a imprecisão descrevem sua forma de existência e de definição. A incompletude também é notável na percepção da existência de um conjunto fuzzy.

Para compreender de maneira intuitiva a diferença entre um Conjunto Clássico e um Conjunto Fuzzy supunhamos a ilustração da figura 19.

Suponhamos agora que Y descreva um universo de discurso cuja enumeração de seus elementos y não possa ser realizada da mesma forma que no exemplo anterior de X . Seja $Y = \{pessoas\ altas\}$ e suponhamos alguns elementos que podem se relacionar com o conjunto Y , sendo $y_1 = \text{”Maria com 1.65m de altura”}$, $y_2 = \text{”João com 1.97m”}$ e $y_3 = \text{”Roberto com 1.78m de altura”}$. Neste caso, o universo Y descreve elementos associados a uma variável de natureza *difusa* onde os limites quantitativos que especificam seu escopo, não são bem definidos ou nem são explicitados.

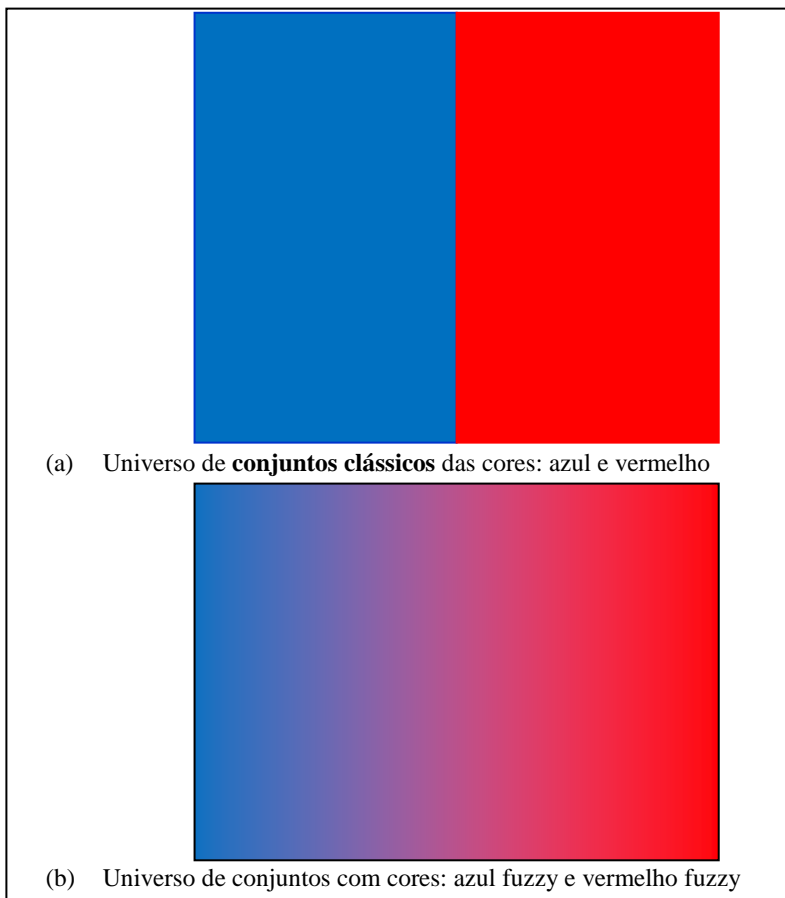


Figura 19 – Exemplificação: conjuntos clássicos e conjuntos fuzzy (cores)

Fonte: (do autor)

O conceito que descreve o conjunto Y , “*peçoas altas*”, pode ter uma intensidade semântica diferente conforme a análise e a percepção de quem verifica. Esta intensidade pode ser medida por um *grau de pertinência* que certifica a *certeza* ou *possibilidade* de que um elemento y está inserido em Y . Assim, de modo sugestivo, segundo a observação conferida por um tipo de *raciocínio aproximativo*, poderíamos dizer que “ y_1 tem 0.6 grau de pertinência ao conjunto (*peçoas altas*), y_2 tem 0.95 e y_3 tem 0.8.

Note que um *grau de pertinência* é uma medida de possibilidade especificada por um coeficiente real no intervalo $[0, 1]$. Conforme verificado em Ross (1995), este intervalo $[0,1]$ é uma maneira típica de representar a forma *normalizada* de expressão de uma medida de certeza possibilística, contudo, pela Teoria da Possibilidade esta medida pode ser aferida e inferida por meio dos mecanismos lógicos das operações *fuzzy* de modo que o coeficiente possa ser maior que 1.

Uma definição formal de um conjunto fuzzy é relatada por Barros (1997, p.14):

Seja X um conjunto clássico. Um subconjunto fuzzy $F = \{(x, \mu_F(x)) : x \in X\}$ onde $\mu_F : X \rightarrow [0,1]$ é uma função chamada de pertinência de x em F com os graus 1 e 0 representando, respectivamente, a pertinência completa e a não pertinências do elemento ao conjunto fuzzy.

A especificação de um domínio representado por variáveis imprecisas perpassa pela análise de conceitos e de relações sobre entidades que descrevem a subjetividade tratada pela modelagem fuzzy. Neste aspecto é importante salientar que em termos semânticos, estes conceitos e relações são normalmente detectados por expressões dadas por meio de proposições fuzzy.

Pela Teoria dos Conjuntos Clássicos ou dos Conjuntos *Crisp* uma proposição é sempre uma sentença afirmativa que denota um valor-verdade (*True* ou *False*). Para exemplificar, elencam-se algumas proposições *crisp* e correlacionam-as com suas respectivas proposições redefinidas numa forma fuzzy:

Proposições clássicas (lógicas ou crisp):

- a) A temperatura está em 42 °C
- b) Roberto tem 25 anos de idade
- c) Ana tem 1.75m
- d) O aluno obteve média maior que 7

Proposições fuzzy:

- e) A temperatura está *quente*
- f) Roberto é uma pessoa *jovem*
- g) Ana é uma pessoa *razoavelmente alta*
- h) O aluno obteve um *bom rendimento escolar*

Note que o valor-verdade das proposições (e) à (h) não podem ser expressados por valores lógicos clássicos, mas, pela medida de possibilidade que afere o *teor de verdade* de cada sentença segundo o universo de discurso em que estão inseridas.

Para um mecanismo de raciocínio fuzzy estes conceitos representados por termos linguísticas devem estar associados a grandezas numéricas numa escala definida pelo denominado *suporte* da variável linguística que está sendo modelada. Estas grandezas, em sua forma real (*Crisp*) devem ser convertidas para valores na forma *fuzzy*. Este processo de um Sistema Fuzzy é denominado *Fuzzificação*, ou seja, a *Conversão Crisp → Fuzzy* (ROSS, 1995).

O entendimento deste processo perpassa pelo estudo da modelagem e aplicação das *funções de pertinência*, que será abordado na unidade seguinte.

2.6.3 Funções de pertinência fuzzy

Quando representamos um conceito subjetivo, incompleto, vago ou impreciso, por meio de uma variável que o quantifique, a qual denomina-se *variável linguística*, esta variável, sendo um conjunto, pode ser organizada por subconjuntos chamados de *termos linguísticos* ou simplesmente *conjuntos fuzzy*. Estes conjuntos, em sua forma agregada, caracterizam a variável linguística e são representados por formas convexas, lineares ou não-lineares por meio de *funções de pertinência* (ZIMMERMAN, 1991).

A notação da função de pertinência é então dada na forma:

$$\mu_A(x)$$

onde, *A* representa o conjunto fuzzy, *x* representa a entrada (*Crisp*) no suporte do conjunto *A* e $\mu(x)$ é o Grau de Pertinência de *x* em relação ao conjunto fuzzy *A*, com valor normalizado no intervalo $[0, 1]$.

Ross (1995) apresenta algumas características que descrevem uma função de pertinência:

1. *Núcleo (core)*: é a região da função de pertinência que define um conjunto fuzzy \tilde{A} cujos valores x do universo resultam em $\mu(x) = 1$;
2. *Suporte*: região da função de pertinência que não anula a função de pertinência, ou seja, $\mu(x) > 0$;
3. *Boundaries*: são os limites do conjunto fuzzy para qual $0 < \mu(x) < 1$.

A figura 20 mostra estas características acima descritas sobre a organização de um conjunto fuzzy:

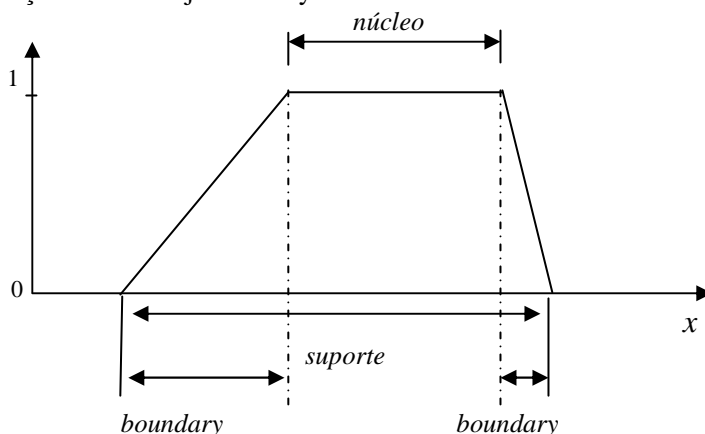


Figura 20 – Núcleo, suporte e *boundaries* de um conjunto fuzzy

Fonte: Adaptado de Ross (1995)

O formato da função de pertinência que irá representar um conjunto fuzzy deve ser analisado de modo a estabelecer uma determinada correlação ao pensamento humano caracterizado pela nossa capacidade de realizar raciocínio aproximado, ao inferir sobre conceitos ou entidades desta natureza subjetiva.

Por exemplo, é de senso comum que, dada uma variável *TEMPERATURA*, em sua forma linguística e, seus subconjuntos fuzzy *fria*, *razoável* e *quente*, sabemos que a mudança de estado *fria* \rightarrow *razoável* e/ou *razoável* \rightarrow *quente*, não ocorre de maneira abrupta, mas, por uma transição gradual que corresponde a uma realidade observada.

Este argumento justifica a escolha de formas lineares (trapezoidais e triangulares) e formas não-lineares (sigmóides e gaussianas) de se conceber a modelagem de imprecisão com funções algébricas em Lógica Fuzzy.

Retomamos um exemplo já citado na unidade (2.5.5) que expressava a variável *PIMC* (*Perfil do Índice de Massa Corpórea, em crianças e adolescentes*). Seja *PIMC* uma variável linguística com seus estados definidos numa forma simplificada (*apenas os três estados mais evidentes*) pelos conjuntos fuzzy: *Magreza*, *Normal*, *Obeso*. A figura 21 irá ilustrar a mudança gradual entre um conjunto e outro, estabelecendo uma sobreposição conceitual que sugere mais adiante na exploração desta pesquisa, a investigação acerca de como lidar com esta sobreposição diante de situações (domínios) com complexa dinâmica.

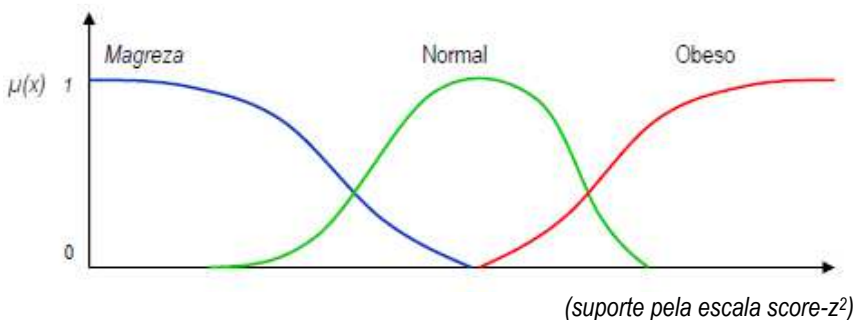


Figura 21 – Representação da variável *PIMC* na forma fuzzy com funções não-lineares

Fonte: (do autor)

Especificado em conformidade com a teoria apresentada por (Ross, 1995), o conjunto *Magreza* está representado pela função *sigmóide reversa* ou *decrecente* cuja equação é dada por:

$$\mu(x) = 1 - \frac{1}{(1 + e^{-a(x-c)})} \quad \text{Eq. (10)}$$

onde, a , e c são parâmetros do formato da função. O conjunto fuzzy *Normal* está sendo representado por uma função *gaussiana* com equação definida por:

² *Score-z* = medida resultante da composição das variáveis envolvidas na análise do índice de massa corpórea. Fonte: (MAYER, 2012)

$$\mu(x) = \frac{e^{-(x-c)^2}}{2\sigma^2} \quad \text{Eq. (11)}$$

Também, o conjunto fuzzy *Obeso* dado por uma função *sigmóide* definido pela equação:

$$\mu(x) = \frac{1}{(1+e^{-a(x-c)})} \quad \text{Eq. (12)}$$

Dependendo da complexidade do fenômeno e do domínio em relevância, a modelagem pode optar pelas formas lineares ou não-lineares que melhor representem a realidade.

Na sequência discutiremos sobre o processo de *fuzzificação*, na conversão *Crisp* \rightarrow *Fuzzy*. Cabe ressaltar que esta etapa é a única contribuição da Lógica Fuzzy ao propósito da construção do modelo de inferência Fuzzy-Bayesiano. Não será necessária a investigação sobre o processo de *inferência fuzzy*, desde a composição da saída a partir da ativação do conjunto de regras, até a etapa final de *defuzzificação* ou conversão *Fuzzy* \rightarrow *Crisp*. A qualidade da modelagem da imprecisão na obtenção dos resultados das funções de pertinência será suficientemente necessário e fundamental para a eficácia do raciocinador *fuzzy-bayesiano* desta pesquisa.

2.6.4 Conversão Crisp-Fuzzy

Nas etapas que conferem a arquitetura de um Sistema Fuzzy existe a conversão de uma grandeza numérica, que representa uma quantidade ou métrica relacionada à variável linguística do domínio. Esta conversão, denominada *fuzzificação*, transforma um número real *Crisp* em um coeficiente $\mu(x) \in [0, 1]$ como sendo a medida fuzzy que corresponde a entrada x no suporte do conjunto fuzzy cujo *alvo* cruze a linha (*equação*) que concebe a forma deste conjunto.

O termo *alvo* é usado para significar a reta que cruza verticalmente a área que define um conjunto fuzzy, portanto, sendo perpendicular ao eixo do suporte da variável linguística no ponto de entrada x (ZIMMERMAN, 1991).

Retomamos o exemplo da variável *PIMC* da figura 17 para mostrar como ocorre a fuzzificação a partir de uma entrada de valor *Crisp* x :




Figura 22 – Processo de *fuzzificação* sobre a variável PIMC

Fonte: (do autor)

A forma gráfica de representação das funções de pertinência mostram claramente, na figura 22, como ocorre a conversão. Note que, para a simulação de uma entrada hipotética x_i ocorreu a obtenção de dois valores $\mu(x)$ quando o *alvo* cruzou as linhas das funções de pertinência dos conjuntos – *Normal* e *Obeso*.

Portanto, como $\mu(x_i)_{Normal} < \mu(x_i)_{Obeso}$ conclui-se que para um indivíduo com valor x_i associado ao *score-z* obtido, este indivíduo, do ponto de vista da *Possibilidade*, é classificado como mais *Obeso* do que *Normal*.

Investigaremos mais adiante a ocorrência de *superposição* cujo *alvo* interceda um número maior que dois estados fuzzy para uma entrada x , pois, segundo Ross (1995, p.557) “*uma medida fuzzy descreve a vagueza ou imprecisão na associação de uma elemento a dois ou mais conjuntos crisp*”.

Conhecida a abordagem probabilística sobre incertezas e também como a imprecisão pode ser modelada com princípios da Lógica Fuzzy, adentraremos no estudo das Redes Fuzzy Bayesianas observando as lacunas que fornecem a oportunidade da contribuição científica para o âmbito do processo de raciocínio probabilístico sobre a imprecisão.

2.7 Redes Fuzzy-Bayesianas

Nesta unidade serão apresentados alguns princípios e argumentos que sugerem a existência de estruturas de Redes de Probabilidade Híbridas na

combinação de métodos para tratamento de incertezas integrando probabilidade e imprecisão.

Durante a etapa de levantamento bibliográfico para identificar-se o Estado-da-Arte das pesquisas com Redes Fuzzy-Bayesianas observou-se que vários trabalhos citaram Viertl (1987) como sendo uma contribuição aparentemente original sobre esta temática. Contudo, referências mais antigas também já discorriam interesses sobre tal.

O Estado-da-Arte das pesquisas com Redes Fuzzy-Bayesianas e algumas soluções vinculando a temática das ontologias para a representação de conhecimento estocástico serão apresentados em capítulo posterior com maior ênfase.

O propósito desta unidade é destacar alguns trabalhos mais similares a esta tese, como, Pan (1999), que foca em regressão fuzzy e cálculo probabilístico numa conjuntura única para prover solução matemática e algorítmica em relação ao aprendizado de Redes Fuzzy-Bayesianas. Também, expor de modo sucinto os trabalhos de Brignoli (2001) e Tibiriçá (2005) que foram precursores de pesquisas acadêmicas no que tange à modelagem, simulação e aplicação de um método de inferência fuzzy-bayesiano de formato dicotômico. Estes trabalhos foram realizados, em princípio, por uma modelagem desenvolvida por Brignoli (2001) e conseqüentemente, aplicada por Tibiriçá (2005). Ressaltar que a pesquisa agora realizada segue pelo mesmo autor, Brignoli (2001) com desenvolvimento mais amplo e com modificações na estrutura do modelo de inferência utilizando novos pressupostos teóricos numa inserção contributiva ao campo da Engenharia do Conhecimento.

2.7.1 Probabilidade sobre eventos fuzzy

Em sua obra focada na modelagem fuzzy destinada às aplicações em Engenharia, Ross (1995) apresenta argumentos e pressupostos que sustentam o interesse nas pesquisas com Redes de Probabilidade sobre eventos fuzzy. O autor sugere o *Método de Decisão Fuzzy Bayesiano* e introduz uma idéia para a obtenção de *probabilidades sobre eventos fuzzy*. Ross (1995) afirma: “*o problema do esquema bayesiano está nos eventos vagos e ambíguos*”.

Não se trata de uma suposição totalmente original, pois Kandel (1986) já desenvolvia uma modelagem matemática complexa baseada em operações de diferenciação e integração com o propósito de oferecer um tratamento probabilístico com fuzzy. Em sua obra o autor reflete sobre a motivação para o desenvolvimento de um tipo de *estatística fuzzy e filosófica* e conceitualmente relacionada com probabilidade subjetiva.

Ross (1995) desenvolve sua proposta partindo de uma abordagem sobre a *Teoria da Utilidade*. Para o autor, a idéia parte da associação de várias alternativas de escolha sobre estados naturais e valores de utilidade para cada uma destas alternativas. Uma função para a obtenção da *utilidade esperada* diante da j -ésima alternativa é dada pela seguinte equação:

$$E(\mu_j) = \sum_{i=1}^n \mu_{ji} \rho(s_i) \quad \text{Eq. (13)}$$

onde μ_j denota o valor de utilidade e $\rho(s_i)$ indica a probabilidade para o i -ésimo estado s .

Estruturas representadas por *árvores de decisão* são utilizadas no suporte a formulação dos esquemas de decisão sobre *utilidade esperada* de uma alternativa e são levadas em consideração aspectos associados ao tipo de informação – *perfeita* ou *imperfeita*.

Na sequência de sua esquematização Ross (1995) apresenta o conceito de *probabilidade de um evento fuzzy* representado pela equação:

$$P(\underset{\sim}{M}) = \sum_{k=1}^r \underset{\sim}{\mu}^{(x_k)} \underset{\sim}{\rho}(x_k) \quad \text{Eq. (14)}$$

onde,

$$\left\{ \begin{array}{l} \underset{\sim}{M} = \text{evento fuzzy} \\ \underset{\sim}{\mu}(x_k) = \text{funções de pertinência para até } k \text{ novas} \\ \text{informações no universo de discurso sobre o evento } \underset{\sim}{M} \\ \underset{\sim}{\rho}(x_k) = \text{probabilidade marginal de } x_k \end{array} \right.$$

Para que este conceito possa ser empregado em raciocínio bayesiano, é necessário que uma coleção de eventos fuzzy $\Phi = \{\underset{\sim}{M}_1, \underset{\sim}{M}_2, \dots, \underset{\sim}{M}_g\}$ estabeleça um *sistema fuzzy ortogonal* (TANAKA *et al.*, 1976 *apud* ROSS, 1995). Este argumento sustenta o fato que as Redes Fuzzy-Bayesianas devem manter o axioma da Teoria da Probabilidade que afirma – *a somatória das probabilidades de um espaço amostral deve ser 1*.

O modelo que será apresentado adiante também deverá considerar que os resultados da propagação da Rede Fuzzy-Bayesiana sobre o vetor de hipóteses diagnósticas, embora, qualificados pela tratativa da imprecisão com Lógica Fuzzy, mesmo assim continuarão sendo de natureza *probabilística*, contudo, há expectativa de numa relevância em torno da

nova semântica e de uma eficácia produzida pelo modelo de raciocínio diante do conhecimento com ambiguidades.

2.7.2 Redes Bayesianas Híbridas

As Redes Bayesianas Clássicas representam variáveis probabilísticas cujos estados são de natureza discreta enquanto que as Redes Bayesianas Híbridas são caracterizadas por uma estrutura capaz de representar e inferir sobre variáveis probabilísticas de natureza discreta e também contínua. A figura 23 apresenta um diagrama com conceitos e relações de dependência que sugere um modelo de Rede Bayesiana Híbrida:

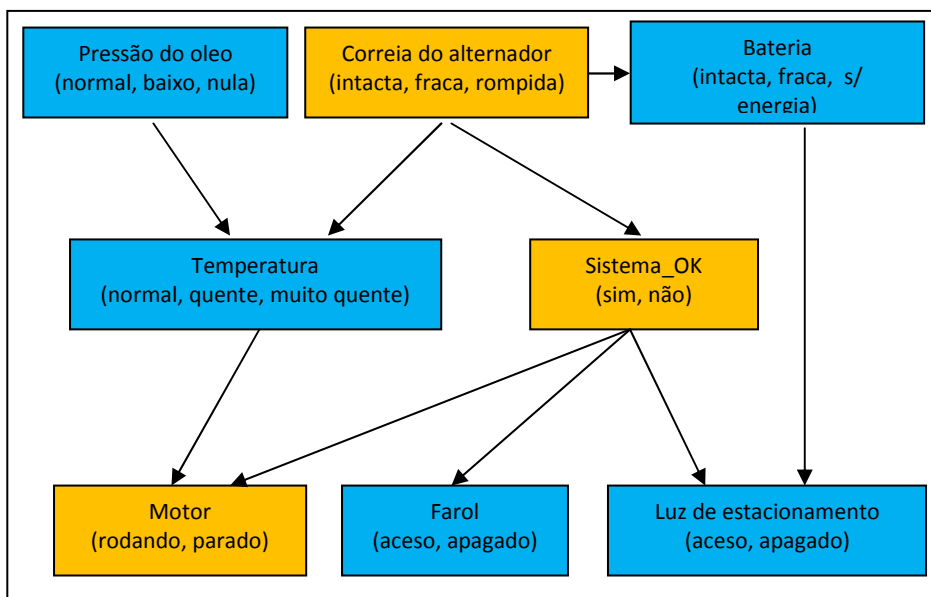


Figura 23 – Diagrama para uma Rede Bayesiana Híbrida

Fonte: Adaptado de Pan (1999)

Os retângulos da figura 23 representam variáveis de um domínio que expressam a incerteza por meio de probabilidades. Em cor laranja estão as variáveis probabilísticas com estados discretos e em cor azul, as variáveis denotam a característica da imprecisão dada pelos seus estados contínuos.

A figura 24 mostra novamente o diagrama, contudo, explicitando o aspecto de continuidade associado aos seus estados.

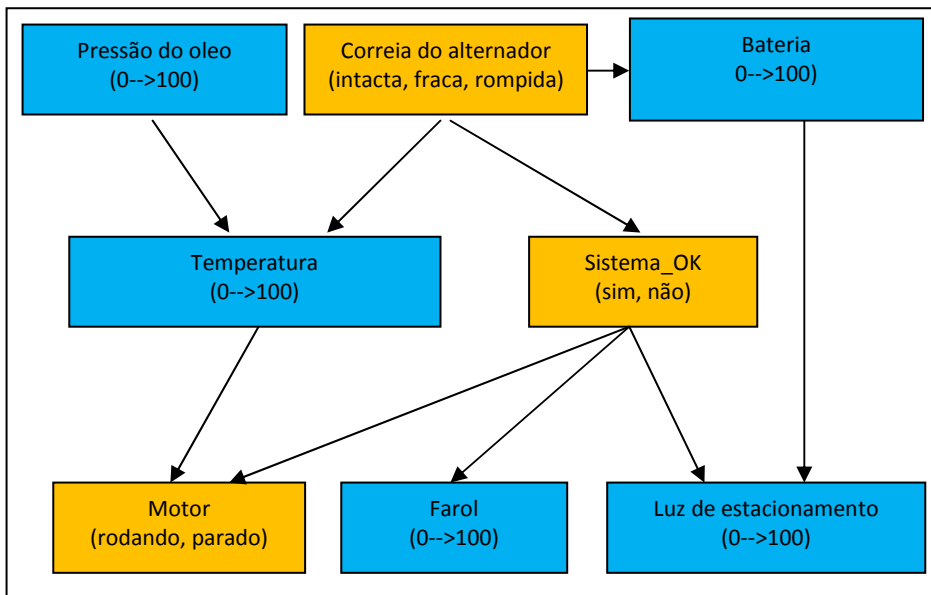


Figura 24 – Diagrama para uma Rede Bayesiana Híbrida destacando as variáveis contínuas

Fonte: Adaptado de Pan (1999)

De acordo com Pan (1999) as Redes Bayesianas Híbridas são extensões das Redes Bayesianas mais tradicionais do ponto de vista do estudo da Probabilidade Condicional, as quais modelam somente variáveis discretas. A motivação para a utilização de Redes Bayesianas Híbridas está associada às demandas de aplicações do mundo real que necessitam deste modelo híbrido. O autor introduz a ideia de utilizar funções de aproximação fuzzy para remodelar a estrutura, a inferência e o aprendizado da rede a partir das variáveis contínuas que esta pode apresentar.

Importante salientar que o uso da Lógica Fuzzy é uma das formas de contribuir com algum hibridismo às Redes Bayesianas. Em unidades posteriores analisaremos outras teorias empregadas à concepção de formas híbridas junto às Redes Bayesianas.

Pan (1999) apresenta uma definição formal para o conceito de Redes Bayesianas Híbridas:

Definição: Uma Rede Bayesiana Híbrida genérica (*HNB*) é um grafo acíclico dirigido (*DAG*) representando uma distribuição de probabilidades

conjuntas de um conjunto de variáveis \mathbf{V} , incluindo variáveis discretas \mathbf{X} e variáveis contínuas $\tilde{\mathbf{Y}}$:

$$HBN = (\mathbf{V}, \mathbf{L}, \mathbf{P}) = (\mathbf{X}, \tilde{\mathbf{Y}}, \mathbf{L}, \mathbf{P}) \quad \text{Eq. (15)}$$

onde, $\mathbf{X} \subseteq \mathbf{V}$ denota um conjunto de variáveis discretas, $\tilde{\mathbf{Y}} \subseteq \mathbf{V}$ um conjunto de variáveis contínuas, \mathbf{L} um conjunto de arcos direcionados entre as variáveis e \mathbf{P} um conjunto de distribuição de probabilidades condicionais.

A contribuição de Pan (1999) estabelece um novo modelo de Rede Bayesiana Híbrida, as denominadas Redes Fuzzy Bayesianas (FBN) e sugere dois formalismos diferenciados: a chamada Forma-I que substitui cada variável contínua por uma variável (pai) discreta e adiciona um arco direcionado do nodo-pai discreto ao filho-contínuo. O mapeamento entre estas duas variáveis é realizado por uma aproximação Gaussiana. O modelo gaussiano é uma função de aproximação fuzzy, porém, a Forma I não utiliza todo o formalismo de inferência da lógica difusa; a Forma-II somente substitui cada variável contínua cujos descendentes incluem variáveis discretas por um nodo-pai discreto e também relaciona-os por meio de um arco direcionado. Já o mapeamento neste caso é realizado por meio de Regressão Gaussiana. A Forma-II é mais complexa em termos de processo de inferência e aprendizado da Rede.

Não serão discutidos aqui os detalhes da formulação. O trabalho é focado em intensa modelagem matemática, desprovido da demonstração prática da sua viabilidade em aplicações reais. Também, discorre sobre o problema da Complexidade Computacional para a execução dos algoritmos de construção e de propagação deste tipo de topologia de Rede de Probabilidade. Estes aspectos não estão inseridos nos objetivos essenciais da investigação desta pesquisa.

2.7.3 Um modelo de Rede Fuzzy-Bayesiana com variáveis dicotômicas

A partir dos pressupostos de Ross (1995) e suas fundamentações teóricas relacionadas a existência das probabilidades sobre eventos difusos, Brignoli (2001) propôs em seu trabalho um modelo de inferência híbrido concebido a partir da modificação algébrica do Teorema de Bayes.

A essência do trabalho de Brignoli (2001) consiste na inserção de qualificadores difusos no esquema de inferência do raciocínio plausível bayesiano. O modelo é matematicamente eficaz e, embora, alterando a forma primitiva do raciocínio bayesiano, preserva, diante da conjuntura das

variáveis do domínio, os princípios mais elementares da Teoria da Probabilidade.

O modelo desenvolvido por Brignoli (2001) possui um escopo focado e restrito a uma aplicação no âmbito do diagnóstico clínico, elaborada para classificar as Reações Adversas sofridas por pessoas que consomem leite com resíduos de antibióticos. Durante a pesquisa e modelagem, Brignoli (2001) observou que as variáveis detectadas no domínio apresentavam relações de dependência probabilística (*induzindo o uso de Redes Bayesianas para classificação*), embora, algumas destas variáveis, no caso, as evidências apresentadas como entrada ao processamento da Rede Bayesiana eram de natureza incompleta e imprecisa, sugerindo o uso de Lógica Fuzzy como técnica de ajuste a imprecisão inerente às variáveis probabilísticas.

Uma das características mais notáveis na formulação do modelo híbrido difuso-probabilístico desenvolvido no trabalho de Brignoli (2001) é o fato do modelo inferir em uma topologia de Rede Bayesiana com variáveis organizadas numa forma dicotômica de seus estados. As equações seguintes especificam o esquema formal do modelo de inferência dicotômico:

$$P(H_i / \delta) = \frac{P(\delta / H_i)}{P(\delta)} \quad \text{Eq. (16)}$$

onde,

$$P(\delta H_i) = P(H_i) \cdot [P(\delta H_i) \cdot \mu_{\varepsilon_1}(\delta) + (1 - P(\delta H_i)) \cdot \mu_{\varepsilon_2}(\delta)] \quad \text{Eq. (17)}$$

e,

$$P(\delta) = \sum_{i=1}^n P(H_i) \cdot [P(\delta H_i) \cdot \mu_{\varepsilon_1}(\delta) + (1 - P(\delta H_i)) \cdot \mu_{\varepsilon_2}(\delta)] \quad \text{Eq. (18)}$$

A dicotomia observada no modelo de Brignoli (2001) através das equações (17) e (18) está no emprego dos elementos ε_1 e ε_2 como

representantes dos estados fuzzy complementares associados aos termos – *AUSÊNCIA* e *PRESENÇA*, das referidas quantidades de resíduos de antibióticos, estas, as entradas *Crisp* das evidências da Rede Bayesiana.

Notadamente, esta dicotomia é uma limitação inerente aos próprios objetivos do trabalho, ou seja, melhorar a distribuição das probabilidades (saídas) da Rede Bayesiana em função da imprecisão de suas evidências (entradas).

O modelo, em sua forma de organização dicotômica dos estados das variáveis de entrada da Rede Bayesiana apresentou alguns aspectos notáveis nas conclusões obtidas por Brignoli (2001). Dentre estas conclusões destacam-se:

1. O modelo preserva o axioma da Teoria da Probabilidade quando a somatória das probabilidades das saídas da Rede Bayesiana após a qualificação híbrida permanece igual a 1 (um);
2. Em relação a distribuição das probabilidades da saída da Rede Bayesiana na sua forma clássica, ou seja, sem ajuste da imprecisão, e a nova distribuição após o processo de qualificação híbrida, esta segunda apresenta a característica principal notada pelo autor: ocorre mudança de informação (novo conhecimento inferido) justamente no ponto da *máxima entropia* do conhecimento da Rede Bayesiana. Segundo Brignoli (2001) “o fato notável é o que se pode chamar de um espalhamento ou um achatamento na distribuição das probabilidades do vetor (saída)”. Conforme observado pelo autor, as probabilidades que antes estavam abaixo do ponto de *máxima entropia*³ agora aumentam e aquelas acima do ponto, diminuem, ou seja, a Rede sofre uma perturbação de modo que as certezas aumentam e diminuem no ponto de maior incerteza.

Tibiriçá (2005) recorre ao modelo híbrido desenvolvido por Brignoli (2001) e amplia seu escopo de aplicação de modo a considerar a representação de uma Rede Bayesiana com variáveis de múltiplos estados, embora ainda com a inferência na forma dicotômica.

As equações seguintes são redefinições que Tibiriçá (2005) realizou sobre as equações (16), (17) e (18) a partir do modelo desenvolvido por Brignoli (2001) e também aplicadas a uma base de conhecimento formada

³ Ponto de máxima entropia, neste caso, refere-se ao ponto em que a Rede Bayesiana apresenta a maior incerteza relacionada à distribuição de suas probabilidades.

por dados levantados pela atividade clínica de diagnose em classificação de Estado Nutricional. Tibiriçá (2005) redefiniu o cálculo de probabilidades condicionais sobre evidências difusas da seguinte forma:

$$P(H_i|\tilde{e}) = [P(\tilde{e}|H_i) * P(H_i)] * [P(\tilde{e})]^{-1} \quad \text{Eq. (19)}$$

sabendo que o *delta tradicional* é formulado por:

$$\Delta = \sum_{i=1}^n [P(e_j / H_i) \cdot P(H_i)] \quad \text{Eq. (20)}$$

estabelece uma forma de *delta aproximado* dado por:

$$\tilde{\Delta} = P(\tilde{e}_j|H_i) = \sum_{i=1}^n [(P(e_j|H_i) * \mu_{ijm}) + (1 - P(e_j|H_i) * \mu_{ijp}) * P(H_i)] \quad \text{Eq. (21)}$$

onde,

μ_{ijm} = maior grau de pertinência obtido no processo de fuzzificação

μ_{ijp} = menor grau de pertinência obtido

A permanência da forma dicotômica é notável na equação (21) quando ocorre a soma de probabilidades complementares associadas, respectivamente, ao maior e menor grau de pertinência obtido na etapa de ajuste de imprecisão das evidências. Logo, o fenômeno do *espalhamento* ou *achatamento* da distribuição das probabilidades no referencial da máxima entropia da Rede Bayesiana permanece em conformidade com as conclusões expostas por Brignoli (2001).

Adiante, na essência desta pesquisa e de modo correlato aos trabalhos desenvolvidos por Brignoli (2001) e Tibiriçá (2005) será induzido um novo modelo de inferência fuzzy-bayesiano com uma abordagem mais qualificada em termos da disposição não dicotômica dos estados das variáveis de entrada da Rede Bayesiana.

O capítulo seguinte explora o denominado *Princípio da Superposição de Estados* buscando compreender como ocorre a superposição de estados quânticos e como este princípio pode ser interpretado e instaciado para o contexto da modelagem de variáveis linguísticas com conceitos superpostos.

A intensão é mostrar a relação entre a *não dicotomia* e a *Superposição de Conceitos* no espectro da imprecisão intrínseca nas variáveis do domínio modelado.

2.8 Princípio da Superposição de Estados

A motivação para anunciar este princípio da Física Quântica e recorrer a sua definição e interpretação ocorreu no momento da análise do problema alvo desta pesquisa no que tange a algumas variáveis envolvidas no processo de Classificação de Risco Metabólico em crianças e adolescentes que é realizado pelo especialista médico.

Observou-se uma acentuada intersecção ou sobreposição conceitual de alguns estados que descrevem estas variáveis de modo a dificultar a classificação justamente em intervalos limítrofes que definem o suporte numérico que representa quantitativamente estes estados.

A inspiração para instanciar o *Princípio da Superposição de Estados Quânticos* para uma forma de *Superposição ou Sobreposição Conceitual* está calcado numa visão multidisciplinar que pluraliza este conceito explorado pela própria definição Linguística – “*ação ou efeito de superpor; estados das coisas que estão superpostas*” (Ferreira, 2013), pela caracterização da ambigüidade em Lógica Fuzzy (Ross, 1995) e pelo denominado princípio da *Complementaridade* definido em Bohr (1995).

Holi e Hyvönen (2006) também referem-se a um tipo de Sobreposição Conceitual quando utilizam de uma operação denominada de *Overlap* para obter um grau de sobreposição de conceitos nas relações semânticas de uma taxonomia em modelos determinísticos.

Sobre a complementaridade, Bohr (1995) descreve que a natureza humana é dotada de duas imagens, logo, onda e partícula são consideradas como complementares da matéria.

Para Araújo (2012) este princípio de complementaridade está presente na combinação linear da função de probabilidade com a respectiva intensidade de pertinência. O autor retrata uma afirmativa do trabalho de Suleman (2009) descrevendo o fato de que em universo heterogêneo faz sentido o emprego de partições difusas deste universo em que cada informação ou indivíduo possa ser membro parcial de mais de um subconjunto deste universo.

Funções de pertinência fuzzy são apropriadas para modelar esta característica de sobreposição conceitual. Contudo, cenários complexos cuja sobreposição e transição conceitual de um estado A para um estado B é acentuadamente dinâmica, como é o da análise do Perfil de Massa Corpórea

em crianças ou adolescentes (Pires, 2012), dificultam a classificação conceitual devido ao alto grau de nebulosidade em seus pontos limítrofes.

Obviamente, para lidar com a imprecisão caracterizada pela existência de conceitos subjetivos e de natureza contínua no cenário do problema, será necessário o emprego de Conjuntos Fuzzy durante a modelagem. Porém, pela *dinâmica* das variáveis descritas anteriormente se torna oportuno utilizar e justificar uma *Superposição de Estados Fuzzy* quando da dificuldade na classificação diante de incertezas segundo o raciocínio médico apoiado pelo modelo aqui desenvolvido.

Segundo Eisberg e Resnick (1985), a medição da incerteza no âmbito da Mecânica Quântica sugere que uma partícula esteja em dois ou mais estados ao mesmo tempo.

Pessoa (2003) apresenta de modo simplificado os postulados que definem os estados quânticos na visão de Eisberg e Resnick (1985). O formalismo da Física Quântica, segundo o autor, é baseado em experimentos com fótons e que propõe os denominados *auto-estados* e *estados ortogonais*. Para Pessoa (2003), um *estado* em um sistema quântico, num certo instante é representado por $|\psi_A\rangle$ ⁴. Esta notação indica que o fóton será detectado com certeza no caminho *A* e devido a esta certeza, este estado é conhecido por *auto-estado* associado ao valor *A* para a posição do fóton.

Assim sendo, a superposição, conforme ilustra Pessoa (2003) sugere:

$$|\psi\rangle = \frac{1}{\sqrt{2}}|\psi_A\rangle + \frac{i}{\sqrt{2}}|\psi_B\rangle \quad \text{Eq. (22)}$$

A soma algébrica envolve coeficientes necessários para manter os estados normalizados, inclusive, podem assumir valores complexos.

Conforme descreve Pessoa (2003), a Física Quântica não trata de questões de interpretação acerca da indagação: *um fóton pode estar em dois lugares ao mesmo tempo?* Segundo o autor, não há preocupação em descrever a realidade que existe além de nossas observações, apenas em fornecer previsões sobre os resultados de medições realizadas em diferentes situações experimentais.

⁴ Notação para estados quânticos. Os termos $|\psi_A\rangle$ e $\langle\psi_B|$ formam um *bracket* (tipo de parêntese), denotando o produto escalar dos vetores de estado (Pessoa, 2003).

Um estado quântico $|\psi\rangle$ pode ter várias interpretações, segundo Pessoa (2003), tais como, *interpretação Ondulatória*, *interpretação Corpuscular*, *interpretação Dualista Realista*, *interpretação da Complementaridade*, esta última considera que o estado $|\psi\rangle$ é meramente um instrumento matemático para realizar cálculos e obter previsões (visão chamada de *instrumentalismo*). Afirma Pessoa (2003) que qualquer combinação linear entre possíveis estados de um sistema quântico também gera um novo estado.

Esta última afirmativa vem convergir com uma observação no problema identificado nesta pesquisa. Em conformidade com o relato do especialista (Pires, 2012), um paciente pode possuir medidas aferidas que, de certo modo, o classificam de maneira sobreposta em termos do seu *perfil de massa corpórea*, colocando-o quase que simultaneamente ou num processo dinamicamente transitório que perpassa pelos estados *SobrePeso*, *Obeso* e *ObesoGrave*. A percepção quanto à sua classificação perante esta dinâmica de *Superposição de Estados* é fundamental para a eficácia de um processo de diagnose e de tomada de decisão por parte do especialista médico quanto ao quadro clínico do paciente.

Considerações sobre a interpretação do *Princípio da Superposição* numa inspiração para a modelagem da imprecisão nesta pesquisa serão abordados em capítulo subsequente.

2.9 Estado-da-Arte do conhecimento sobre incertezas

Este capítulo apresenta o processo de análise exploratória de artigos com características correlatas a esta pesquisa no que refere-se a utilização de teorias e práticas destinadas a manipulação do conhecimento sobre incertezas.

Inicialmente, realizou-se uma revisão abrangente aplicada sobre a base de artigos científicos – *Scopus*, objetivando o dicernimento prévio sobre o Estado-da-Arte das pesquisas que circundam a temática do conhecimento estocástico e para a preparação do estágio de identificação da lacuna de pesquisa.

Apesar da eficácia dos resultados desta etapa, houve a necessidade de uma exploração mais detalhada e estruturada que contemplasse a busca por indicadores da produção científica relacionada com a temática da tese. Para tal, procedeu-se com um processo de Revisão Sistemática estendido às bases – *IEEE*, *Elsevier* e *Springer*, das quais aplicou-se a análise bibliométrica da massa de documentos pesquisados.

2.9.1 Análise exploratória abrangente

Conforme já mencionado anteriormente, para prover a imersão nas pesquisas já realizadas nesta área de representação e raciocínio sobre conhecimento baseado em incertezas, utilizou-se da exploração abrangente de artigos científicos na base *Scopus*. Nesta etapa, o processo não estruturou exaustivamente o conjunto de termos utilizados na operacionalização da ferramenta de busca. O apêndice A mostra os resultados da busca com a primeira estratégia adotada e com termos escolhidos pela abrangência da temática de pesquisa.

Observou-se a partir do uso da palavra-chave - *Knowledge Engineering*, uma maior concentração de trabalhos realizados no âmbito das Ciências Ambientais, Negócios, Gestão e Contabilidade e ainda, a Engenharia de Conhecimento focada nos estudos da Ciência da Computação.

Esta última sugere uma forte intersecção existente entre as técnicas e implementações computacionais que oferecem suporte à construção de ferramentas destinadas a Engenharia do Conhecimento. Denota ampla forma de pesquisa interdisciplinar entre a Computação e a Engenharia do Conhecimento.

Os apêndices B e C mostram as tabelas resultantes do refinamento da busca por meio de termos mais qualificados em conformidade com a meta desejada.

A estratégia inicial mostrou resultados muito abrangentes e, considerando a magnitude da base de dados *Scopus*, o processo de revisão e análise de conteúdos publicados seria excessivamente exaustivo, dificultando a forma de investigação. Logo, adotou-se um refinamento da busca por meio do uso do operador *AND*. Desta forma, a nova estratégia de busca organizou os termos chave da seguinte maneira:

FUZZY and BAYESIAN and NETWORK and INFERENCE and ONTOLOGY and MEDICAL

Este novo conjunto de termos chave resultou na busca de 2.598 obras publicadas em uma variedade de periódicos, tais como journals, anais de eventos e outras formas de disseminação devidamente registradas nas bases vinculadas a *Scopus*, sendo que uma grande parcela dos trabalhos encontrados está representada por artigos científicos completos, porém, também foram encontradas várias teses de doutorado.

O refinamento da busca para se atingir trabalhos mais evidentes que pudessem contribuir com o levantamento do Estado-da-Arte para com a

presente pesquisa foi orientado, em primeiro lugar, por uma leitura amplamente dinâmica a partir dos títulos e dos resumos dos trabalhos encontrados. Assim sendo, a motivação para a seleção e o aprofundamento da leitura e entendimento dos trabalhos partiu de algum grau de correlação entre o contexto apresentado no resumo com os macro-objetivos nesta estabelecidos.

Cabe ressaltar que em algumas pesquisas foram desenvolvidos aprimoramentos da teoria da probabilidade aplicado ao tratamento de incertezas, porém, com um objetivo maior de incrementar as próprias pesquisas no campo da matemática e da estatística, trabalhando essencialmente com modelos matemáticos absolutos, ou seja, desprovidos, a priori, de serem utilizados para algum fim ou aplicação, especialmente como uma contribuição ao acervo metodológico da Engenharia do Conhecimento.

O apêndice D mostra o quadro organizado para a análise e discussão das resultantes da busca aplicada utilizando-se da *string*⁵ referida anteriormente. O quadro do apêndice D apresenta em cada linha a identificação do trabalho (título e autoria), espaço para anotação de resumo, descrição do enquadramento da abordagem utilizada pelo autor (probabilística, possibilística ou híbrida), as principais características abordadas e o ano de publicação.

É importante salientar que para o cumprimento dos objetivos desta pesquisa, os esforços de investigação dos documentos concentraram-se mais àqueles que utilizaram-se de abordagens híbridas para o tratamento do conhecimento estocástico.

Na sequência far-se-á a síntese das observações dos resultados obtidos na etapa de revisão abrangente que objetivou refinar o espaço de oportunidades, em termos da identificação de pergunta de pesquisa e das suposições e argumentos utilizados para assegurar a sustentabilidade teórica do artefato proposto nesta pesquisa.

Cabe ressaltar a necessidade do emprego da visão sistêmica neste processo que observa possíveis lacunas não relevadas nas metas ou no significado dos resultados alcançados, focados pelos trabalhos revisados, assegurando a singularidade do modelo matemático aqui desenvolvido sendo a essência da tese que será apresentado posteriormente, com originalidade em termos de contribuição teórica ao campo da Engenharia do Conhecimento, especificamente às abordagens relacionadas ao raciocínio

⁵ Refere-se ao conjunto de termos-chave e a forma de agregação destes termos para o processo de busca.

sobre conhecimento baseado em incertezas. Os pontos mais evidenciados para cada trabalho analisado são apresentados pelo quadro 1:

Trabalho	Destaques	Contribuições e Similaridade de Proposta para com esta pesquisa
<i>Fuzzy Bayesian Network – A General Formalism for Representation, Inference and Learning with Hybrid Bayesian Networks.</i> Pan, Heping. (1999)	Trabalho original; abordagem híbrida; modelagem matemática; não foca em aplicação para Engenharia do Conhecimento; discorre sobre complexidade computacional.	- Interessado em modelo para variáveis discretas e contínuas; - Conjunção das técnicas Fuzzy e Redes Bayesianas; - Utiliza apenas processo de fuzzificação da Lógica Fuzzy.
<i>A Probabilistic Extension to Ontology language OWL.</i> Ding, Zhongli; Peng Yun. (2004) e <i>Bayes OWL: A Probabilistic framework for Uncertainty in Semantic Web.</i> Ding, Zhongli. (2005)	Abordagem probabilística; propõem o uso de ontologias para representação de incertezas; modificam o esquema OWL para inserir anotações probabilísticas; trata somente a incerteza representada por probabilidades.	- Inspiração para o argumento de tese sobre a construção de ontologias fuzzy-bayes por meio da discussão sobre os constructos necessários para representar este tipo de conhecimento em ontologias.
<i>Bayesian Semantics for the Semantic Web.</i> Costa, Paulo Cesar G. (2005)	Similaridades aos dois trabalhos anteriores; estende o uso das Redes Bayesianas Multi-Entidades para realizar inferência na Web Semântica; abordagem probabilística.	- Somente no que refere-se à inferência sobre incertezas; - Não possui forte correlação.
<i>Modeling Uncertainty in Semantic Web Taxonomies.</i> Holi, Markus; Hyvönen, Eero. (2006)	Trabalho original; discorre sobre o conceito de <i>Overlap</i> ; utiliza abordagem probabilística para inferência,	- Contribui ao discorrer sobre a <i>Sobreposição Conceitual</i> na representação do conhecimento.
<i>Integration Uncertain Knowledge in a Domain Ontology for Room Concept Classifications.</i>	Trabalho focado em aplicação; utiliza uma abordagem híbrida; para representação da incerteza	- Somente no que refere-se à inferência sobre incertezas; - Não possui forte

<p><i>Hois, Joana; Schill, Kerstin; Bateman, John. (2007)</i></p>	<p>recorrendo ao emprego de Lógica Fuzzy e Teoria de <i>Dempster-Shafer</i>; medidas de crença são analisadas em termos da imprecisão nas relações conceituais representadas pela ontologia.</p>	<p>correlação.</p>
<p><i>An Ontology-based Bayesian Network Approach for Representing Uncertainty in Clinical Practice Guidelines. Zheng, Hai-tao; Kang, Bo-Yeong; Kim, Hong-Gee. (2007)</i></p>	<p>Abordagem probabilística; trabalho focado em aplicação; não trata qualquer nova proposta de formalismo ao processo de inferência; enaltece o uso de Redes Bayesianas no compartilhamento de conhecimento médico.</p>	<p>- Enfatiza a necessidade de estruturas de compartilhamento do conhecimento médico; - Sugere aproximar soluções estocásticas e ontologias.</p>
<p><i>Combining uncertain Outputs from Multiple Ontology Matchers. Wang, Ying; Liu, Weiru; Bell, David. (2008)</i></p>	<p>Abordagem híbrida empregando Lógica Fuzzy e Teoria de <i>Dempster-Shafer</i>.</p>	<p>- Contribui ao enfatizar a necessidade do emprego de abordagens híbridas e com outras técnicas para lidar com o problema da imprecisão no conhecimento representado por ontologias.</p>
<p><i>Probabilistic Models for the Semantic Web – A Survey. Predoiu, Livia; Stuckenschmidt, Heiner. (2009)</i></p>	<p>Não se trata de um trabalho original; uma compilação das soluções já desenvolvidas no âmbito da representação do conhecimento por ontologias probabilísticas.</p>	<p>- Reporta-se às contribuições de <i>Ding, Zhongli; Peng Yun. (2004) e Ding, Zhongli. (2005)</i>, no que refere-se às modificações e inserções nas linguagens de construção de ontologias.</p>
<p><i>Probabilistic Ontology: Representation and Modeling Methodology. Carvalho, Rommel Novaes. (2011)</i></p>	<p>Abordagem probabilística; uma extensão a partir da proposta da PR-OWL; novas modificações permitiram a PR-OWL 2 lidar com maiores complexidades nas estruturas das ontologias; um incremento da proposta foi solucionar o problema da escalabilidade.</p>	<p>- Também reporta-se às mesmas contribuições de <i>Ding, Zhongli; Peng Yun. (2004) e Ding, Zhongli. (2005)</i></p>
<p><i>Um Modelo de Engenharia</i></p>	<p>Abordagem probabilística;</p>	<p>- Enaltece o emprego de</p>

<p><i>do Conhecimento Baseado em Ontologia e Cálculo Probabilístico voltado ao Processo de Diagnóstico. Lopes, Luiz Fernando; Gonçalves, Alexandre Leopoldo; Todesco, José Leomar. (2011)</i></p>	<p>trabalho focado em aplicação de diagnóstico médico usando também a capacidade de inferência das Redes Bayesianas e de estrutura de representação de conhecimento. O diferencial do trabalho foi utilizar software de revisão de texto no processo de <i>KDD (Knowledge Data Discovery)</i>.</p>	<p>abordagens estocásticas no tratamento do conhecimento sobre incertezas no âmbito da medicina.</p>
<p><i>Fuzzy ontology representation using OWL 2. Bobillo, Fernando; Straccia, Umberto. (2011)</i></p>	<p>Abordagem possibilística; trabalho apresenta uma forma de representar conceitos vagos por meio da inserção de anotações difusas de variáveis imprecisas no esquema RDF/OWL 2. Um <i>plugin</i> para o software <i>Protégé</i> foi desenvolvido para que a ontologia representasse e inferisse sobre conceitos e relações imprecisas.</p>	<p>- Demonstra a relevância da Lógica Fuzzy e da representação do conhecimento sobre imprecisão no âmbito das ontologias; - Esta proposta reforça a relevância da aproximação de soluções estocásticas para a representação do conhecimento em ontologias; - Por ser uma abordagem possibilística em contraste com a maioria das propostas que empregam o conceito unilateral de probabilidade, este trabalho pode propiciar ao engenheiro do conhecimento vislumbrar o desenvolvimento de modelos híbridos que inferem sobre probabilidade e imprecisão, sugerindo mecanismos de suporte ao raciocínio sobre ontologias que representam este tipo de conhecimento híbrido caracterizado em um domínio complexo.</p>

Quadro 1 - Discussão dos resultados da etapa de revisão abrangente

(Fonte: do autor)

Conforme justificado anteriormente, esta primeira etapa de exploração de artigos, realizada de uma forma abrangente, trouxe alguns insumos, em Pan (1999), Ding (2004 e 2005) e Carvalho (2011), para identificar a panorâmica das pesquisas no âmbito da representação e inferência do conhecimento sobre incertezas e que norteou a etapa de desenvolvimento do projeto de pesquisa da tese de doutorado.

Contudo, tornou-se necessário uma análise mais sistematizada sobre os indicadores de produção científica acerca da temática da representação do conhecimento sobre incertezas. Para tal, desenvolveu-se uma segunda etapa de análise e revisão sistemática adotando-se de critérios mais estruturados de acordo com as recomendações de Mulrow (1994) e Kitchenham (2004).

2.9.2 Pesquisa Sistemática

2.9.2.1 Motivação

Esta etapa estruturada do processo de revisão de artigos e análise do Estado-da-Arte fornece informações para o entendimento mais apurado acerca da evolução temporal do desenvolvimento da pesquisa no campo da representação do conhecimento estocástico, oportunizando a busca pelos indicadores de produção que apontaram o volume de trabalhos desenvolvidos nos últimos anos e os autores mais referenciados.

Além destes dados o processo estruturado propiciou, segundo os critérios utilizados em conformidade com Mulrow (1994) e Kitchenham (2004), a classificação de um conjunto de artigos mais apropriados para a análise e discussão sobre os aspectos relevantes que apresentam similaridades aos propósitos desta tese.

Adotou-se da utilização do processo estruturado de revisão sistemática por entender da necessidade de melhor qualificar a característica de ineditismo desta tese frente às teorias e práticas já desenvolvidas.

A revisão sistemática consiste numa metodologia de investigação que identifica, analisa e interpreta as informações documentadas que estão relacionadas a uma pergunta de pesquisa (MULROW, 1994) e (KITCHENHAM, 2004).

Na sequência será apresentado todo o processo de organização da revisão sistemática, desde a escolha do portfólio de artigos, perpassando por uma análise bibliométrica até a análise de documentos selecionados para discussão.

2.9.2.2 Seleção de artigos

Seguindo as recomendações de Mulrow (1994) e Kitchenham (2004) para o processo de Revisão Sistemática especificou-se algumas questões que norteariam a investigação, a análise e a discussão dos conteúdos dos artigos revisados:

- (i) Quais os trabalhos que desenvolveram abordagens híbridas para o tratamento do conhecimento sobre incertezas?
- (ii) Deste conjunto (i) quais relacionam-se com o estudo de Ontologias?
- (iii) Dos trabalhos do conjunto resultante da questão (i) quais propuseram a solução combinando Lógica Fuzzy com Redes Bayesianas?
- (iv) Sobre este novo conjunto de trabalhos selecionados quais estão centrados em modelagem matemática modificando essencialmente o esquema de inferência bayesiano?
- (v) Estes trabalhos discorrem sobre a Complexidade do Conhecimento sobre Incertezas, recorrendo assim ao emprego de uma forma transdisciplinar para obter a solução no campo da *inferência* sobre este tipo de conhecimento?
- (vi) Também, são trabalhos aplicados (artefatos tecnológicos) com parâmetros limitados para atender a uma demanda específica?

Definidos os questionamentos acima, realizou-se a etapa primária do processo de busca sobre as bases *IEEE*, *Elsevier* e *Springer* adotando-se da elaboração das *strings* de busca conforme ilustra o quadro 2:

Busca	Conjuntura de Termos	Base		
		IEEE	Elsevier	Springer
1	("fuzzy") and ("bayesian") and ("inference") or ("reasoning")	65	6016	3517
2	("fuzzy") and ("bayesian") and ("network") and ("inference") or ("reasoning") and ("ontology") and ("medical")	Sem refinamentos de busca	195	Redefinição de strings para as buscas: 5, 6 e 7.
3	("fuzzy") and ("bayesian") and ("network") and ("inference") or ("reasoning") and ("ontology") and ("medical") and ("hybrid")	Sem refinamentos de busca	115	
4	("fuzzy bayesian") and ("inference") or ("reasoning")	Sem refinamentos de busca	102	
5	'fuzzy AND bayesian AND network AND inference'	Não aplicado	Não aplicado	2736
6	'fuzzy AND bayesian AND inference AND method AND hybrid'	Não aplicado	Não aplicado	1066
7	'fuzzy AND bayesian AND inference AND method AND hybrid AND ontology'	Não aplicado	Não aplicado	184
8	'fuzzy-bayesian'	Não aplicado	Não aplicado	98

Quadro 2 - Organização de *strings* e resultados da busca primária

(Fonte: do autor)

As *strings* de busca foram elaboradas de múltiplas formas em razão da qualidade do volume de artigos resultantes em cada uma das bases escolhidas. Observou-se que, dependendo da especificação destas *strings*, os resultados eram por vezes, muito heterogêneos de uma base para outra além de, em alguns casos, não convergirem para o apontamento de documentos que estivessem no escopo do interesse desta investigação.

Para a formação do primeiro conjunto do portfólio da pesquisa delimitou-se e resgatou-se um total de 564 artigos levantados por: *IEEE* = 65 artigos, *Elsevier* = 115 artigos + 102 artigos, especificando que, buscaram-se os artigos sobre 'Fuzzy' e/ou 'Bayesian' e depois, a conjunção 'Fuzzy Bayesian', *Springer* = 184 artigos e *Springer* = 98 artigos, também

nesta base buscou-se documentos relacionados às formas disjuntas e conjuntas dos termos, *Fuzzy* e *Bayesian*.

Após esta etapa eliminou-se as duplicações, procedeu-se com a leitura dos títulos, resumos e conclusões dos artigos para identificar maior grau de correlação com as questões (i) à (vi) delineadas anteriormente. Como resultante desta segregação obteve-se 96 artigos mais qualificados para a continuidade do processo de revisão. Todo este processo foi operacionalizado com os recursos de exportação das informações e de metadados dos documentos catalogados nas bases científicas utilizadas. Também, recorreu-se ao uso do software *EndNote 3.5*, versão *Web*, um gerenciador de referências bibliográficas, e ainda, planilha eletrônica MS-Excel para a organização de filtros de consulta e produção dos gráficos que serão ilustrados na análise bibliométrica.

Na sequência procedeu-se com a leitura mais detalhada do conteúdo dos 96 artigos segregados anteriormente chegando-se a um conjunto mais refinado de 40 trabalhos dos quais elencou-se os mais citados por outras obras segundo os indicadores de consulta obtidos por meio da utilização do software *Google Scholar*.

Com este último conjunto de 40 documentos procedeu-se com a releitura de seus conteúdos, levando-se em consideração o *ranking* de suas citações, o ano de publicação e, novamente, as maiores características de similaridade com esta pesquisa de tese, discorridas na essência do desenvolvimento destes trabalhos. Este conjunto de 40 documentos tornou-se propício à elaboração de algumas informações bibliométricas que serão ilustradas adiante. Por fim, chegou-se ao número de 29 artigos selecionados para a etapa de análise e discussão.

2.9.2.3 Análise bibliométrica

A partir então do conjunto anterior de 40 documentos alcançados pela penúltima etapa de segregação dos artigos para análise e discussão elaborou-se alguns indicadores bibliométricos relevantes para elucidar a evolução temporal do Estado-da-Arte das pesquisas relacionadas ao tratamento do conhecimento sobre incertezas.

A figura 25 mostra inicialmente o histograma do número de trabalhos publicados por ano no universo destes 40 documentos:




Figura 25 – Números de trabalhos publicados por ano ao conjunto de 40 documentos

Fonte: (do autor)

Para averiguar o indicativo da figura 25 realizou-se a busca pelo volume de publicações na base *Springer* no mesmo intervalo delimitado na figura 25 especificando a *string* de busca por: *'fuzzy'* AND *'bayesian'* AND *'inference'*. O resultado mostrado pela figura 26 converge com este indicativo:

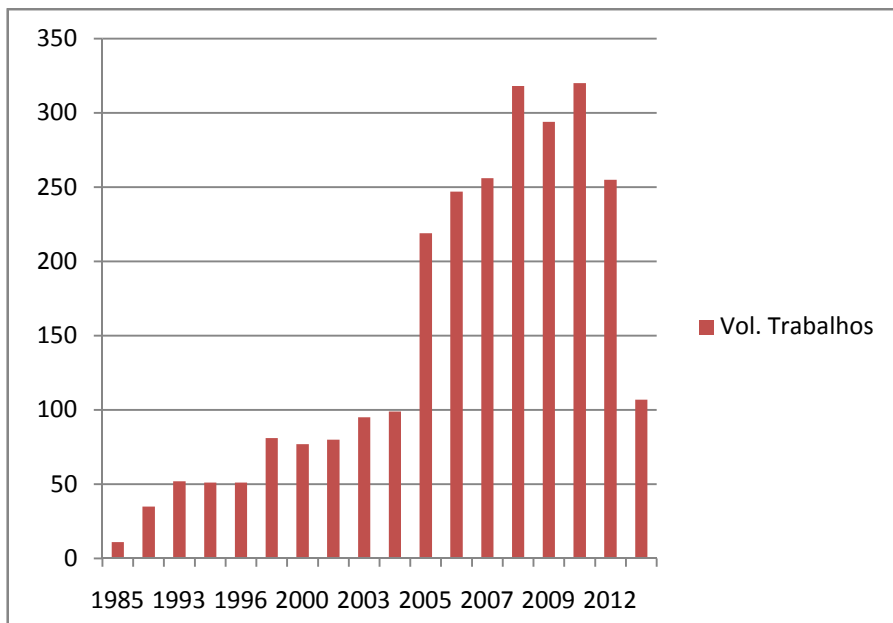


Figura 26 – Volume de trabalhos publicados por ano ao conjunto de 40 documentos–Base *Springer*

Fonte: (do autor)

Ao confrontar-se os histogramas das figuras 25 e 26 observa-se um interesse pela temática da pesquisa, na conjunção dos termos da *string* anterior, concentrado no entorno do ano de 1993 com certa estabilização até meados de 2004 e um incremento considerável em torno do ano de 2011.

A evolução temporal ilustrada pela figura 26 sugere suposições associadas a dois subintervalos entre 1985 e 2013:

- (I) A proposta de Zadeh (1965) pode ter demorado a disseminar na comunidade científica como proposta ao tratamento de incertezas no campo da Engenharia do Conhecimento, tão pouco esta comunidade, vislumbrar soluções com base em abordagens híbridas (probabilidades sobre eventos difusos), supostas por Kandel (1986) e Ross (1995);
- (II) Um interesse crescente a partir de 2005 em torno da temática do tratamento de incerteza. Isso é notório e averiguado pelo crescente número de trabalhos que recorreram ao uso de abordagens estocásticas no âmbito do estudo das ontologias

para Web Semântica, conforme observados em alguns trabalhos como Ding e Peng (2004), Costa (2005), Holi e Hyvönen (2006) e outros.

Conforme mencionado anteriormente, com o mesmo conjunto de 40 documentos segregados na penúltima etapa de seleção procurou-se, por meio da utilização do software *Google Scholar*, identificar os trabalhos mais citados, conforme ilustra a figura 27. Este indicador sugere o grau de importância dado pelas contribuições originais destes trabalhos na continuidade do processo de investigação científica sobre as abordagens híbridas para tratamento do conhecimento estocástico.




Figura 27 – Autores mais citados do conjunto de 40 artigos selecionados

Fonte: (do autor)

A figura 27 é rerepresentada no apêndice E de forma expandida, contudo, observou-se o trabalho de Prade (1985) intitulado como “*A Computational Approach to Approximate and Plausible Reasoning with Applications to Expert Systems*” como sendo um trabalho citado por 225 outros artigos. Em seu conteúdo, o autor recorre aos trabalhos mais originais de Lotfi Zadeh e Abraham Kandel que discorrem sobre a Teoria da Possibilidade e sobre as Probabilidades de eventos difusos, dados estes

que reforçam a suposição (I) anterior, ou seja, Zadeh e Kandel contribuíram com argumentações e conjecturas matemáticas que parecem emergir como pressupostos teóricos para as pesquisas que se interessam pela temática da Engenharia do Conhecimento ao final da década de 90 e tornando-se crescente até os últimos anos conforme mostraram as figuras 25 e 26.

Na sequência será apresentada a etapa de análise e discussão dos últimos 29 artigos selecionados para efetivamente obter-se as informações relevantes do Estado-da-Arte das pesquisas em torno da temática desta tese.

2.9.2.4 Análise da Revisão Sistemática

Com base na leitura íntegra dos 29 artigos selecionados no processo anterior e utilizando-se das questões (i) à (vi) da unidade (2.9.2.2) efetuou-se a análise dos conteúdos a fim de identificar os principais insumos e características destes trabalhos em correlação a contribuição essencial desta tese de modo a perceber a lacuna de pesquisa que evidencia o ineditismo em termos da concepção de uma modelagem para inferência sobre o conhecimento estocástico em domínio dinâmico e complexo.

O quadro 3 é organizado de modo a atender às questões que nortearam o processo de seleção do portfólio de artigos apontando quais autores contemplam estas questões em suas pesquisas.

Características Observadas	Autores
Abordagem híbrida para representar incertezas	Prade (1985); Frühwirth-Schnatter (1990, 1992); Taheri e Behboodian (2001); Römer e Kandel (1995); Yang, Bonsall e Wang (2008); Wu (2004a, 2004b, 2006); Borgelt e Kruse (1997); Fan <i>et al.</i> (2011); Mahler (1995); Gertner e Zhu (1996); Tang e Xu (2005); Yang (1997); Baldwin e Tomaso (2003, 2008); Su (2008); Taheri Zarei (2011); D'angelo <i>et al.</i> (2011); Chen (2000); Wang, Gao e Thompson (2009); Baldwin (1992);

	Smimou, Bector e Jacoby (2007); Fogelberg, Palade, e Assheton (2008); Costa <i>et al.</i> (2011); Ferreira e Borenstein (2012); Coletti <i>et al.</i> (2012); Huang, Zuo e Sun (2006).
Relaciona o estudo de Ontologias	Costa <i>et al.</i> (2011).
Integra Lógica Fuzzy e Redes Bayesianas no processo de inferência	Frühwirth-Schnatter (1990, 1992); Taheri e Behboodan (2001); Yang, Bonsall e Wang (2008); Wu (2004, 2004b, 2006); Gertner e Zhu (1996); Tang e Xu (2005); Yang (1997); Baldwin e Tomaso (2003, 2008); Taheri Zarei (2011); Chen (2000); Wang, Gao e Thompson (2009); Baldwin (1992); Fogelberg, Palade, e Assheton (2008).
Modelagem Matemática com modificações no esquema de inferência bayesiano	Frühwirth-Schnatter (1990, 1992); Taheri e Behboodan (2001); Yang, Bonsall e Wang (2008); Wu (2004, 2004b, 2006); Mahler (1995); Gertner e Zhu (1996); Tang e Xu (2005); Yang (1997); Baldwin e Tomaso (2003, 2008); Wang, Gao e Thompson (2009).
Aborda Complexidade e/ou recorre a formas transdisciplinares	Obs. Os trabalhos que discorrem sobre Complexidade referem-se à Eficiência Algorítmica e não como uma abordagem em termos epistemológicos. Também, o problema da complexidade do conhecimento sobre incertezas é abordado por alguns autores como Costa <i>et al.</i> (2011), e discutido em

	termos do emprego de um conjunto de múltiplas técnicas do próprio escopo da Inteligência Artificial.
Aplicado a demanda específica	Frühwirth-Schnatter (1992); Borgelt e Kruse (1997); Fan <i>et al.</i> (2011); Gertner e Zhu (1996); D'angelo <i>et al.</i> (2011); Wang, Gao e Thompson (2009); Smimou, Bector e Jacoby (2007); Fogelberg, Palade, e Assheton (2008); Costa <i>et al.</i> (2011); Ferreira e Borenstein (2012); Coletti <i>et al.</i> (2012); Huang, Zuo e Sun (2006).

Quadro 3 – Identificação das características observadas na Revisão Sistemática
Fonte: (do autor)

Após analisar o conteúdo completo dos 29 artigos segregados na última etapa do processo de seleção e identificar suas principais características em conformidade com o propósito da organização do quadro 3, observou-se, de maneira especial, os aspectos de originalidade das propostas que geraram alguma teoria ou artefato produzido de modo a contemplar os itens relevados pelas questões (i) à (vi) anteriormente especificadas.

Logo, conclui-se que Yang (1997) e, Baldwin e Tomaso (2003, 2008) trouxeram em seus trabalhos os elementos e formas mais correlatas a esta tese no que refere-se à representação e inferência sobre conhecimento baseado em incertezas.

Contudo, dois aspectos descritos nas questões (ii) e (v) não foram contemplados por Yang (1997) e, Baldwin e Tomaso (2003 e 2008). Primeiramente, não observou-se qualquer relação de interesse ao emprego de *ontologias*, mesmo que na forma da suposição de constructos, para a representação da incerteza por aleatoriedade dada a existência de imprecisão. Também, estes trabalhos não recorrerem a uma maneira transdisciplinar de propor solução à problemática considerada nesta pesquisa, extrapolando os limites das técnicas de Inteligência Artificial, as quais são realmente empregadas de modo exaustivo, como, a Teoria de

Dempster-Shafer, Redes Neurais Artificiais, Algoritmos Genéticos entre outras técnicas descritas em todos os artigos revisados.

O argumento desta tese quando discorre sobre a maneira transdisciplinar no processo de investigação é sim, de recorrer às ciências vizinhas para encontrar elementos que possam implicar em uma “*quebra de paradigma*” no modo linear do pensamento do pesquisador. Esta tese, ao investigar e utilizar-se do argumento da Superposição de Estados Quânticos, mostra relevar esta argumentação, elucidando a caracterização da singularidade ou ineditismo da pesquisa.

Considerado todo o processo de Revisão da Literatura e, principalmente, do levantamento do Estado-da-Arte o capítulo seguinte apresenta o desenvolvimento da abordagem pretendida como tese de doutorado em contribuição científica à área de Engenharia do Conhecimento. O desenvolvimento ocorre em consonância com a problemática e a oportunidade de atuação do Engenheiro do Conhecimento no espaço do problema, os objetivos almejados e a relevância, *a priori*, observada.

3 MODELO DE INFERÊNCIA FUZZY-BAYESIANO

O objetivo deste capítulo é apresentar o desenvolvimento da pesquisa em termos da construção do artefato proposto como modelo e da sua conjectura formal associada aos princípios teóricos fundamentais que foram revisados e explorados na etapa de investigação sistemática. Também, propõe-se demonstrar os resultados alcançados pela aplicação simulada, bem como da interpretação destes resultados e suas considerações conclusivas como solução frente à problemática identificada no início da pesquisa e em consonância com a descrição verificada no processo de raciocínio clínico.

3.1 Perspectiva de tratamento do conhecimento incerto

Conforme já apresentado em unidades anteriores, o cenário característico da problemática desta pesquisa está associado a um processo cuja atividade de raciocínio do especialista é intensiva em conhecimento e a complexidade inerente às variáveis, seus conceitos e relações denota a manifestação de duas formas de incerteza: a aleatoriedade e a imprecisão.

A essência do modelo é oferecer uma nova forma de realizar a inferência diante de uma estrutura de Rede Bayesiana que é composta por estas duas formas de incerteza.

A formalização conjunta que utilizará de abordagem híbrida para tratamento probabilístico e possibilístico é que contribuirá para este modelo se caracterizar como uma forma de qualificação Fuzzy-Bayesiana de conhecimento.

É importante salientar que esta tese não objetiva centrar esforços em contribuição a especificações lógicas e físicas no âmbito da Engenharia de Ontologias, embora, necessite referenciar o assunto frente à suposição de futuras oportunidades de pesquisa em continuidade a esta modelagem.

O estudo realizado na revisão do Estado-da-Arte mostrou a existência de trabalhos que contribuíram especificamente para a elaboração de constructos de ontologias com abordagem estocástica, embora, num tratamento unilateral – Probabilístico OU Possibilístico.


Se estes constructos já viabilizados e concretizados em linguagens como *PR-OWL* (COSTA, 2005), *Bayes OWL* (DING, 2005) e *Fuzzy Ontology-OWL 2* (BOBILLO, 2011) puderam ser implementados em ferramentas de suporte a elaboração de Sistemas de Conhecimento então é factível e oportuno pensar que constructos *fuzzy-bayesianos* possam ser

elaborados para propiciar a construção de ontologias que represente este tipo de conhecimento sobre incertezas.

A figura 28 propõe ilustrar as etapas deste processo de qualificação híbrida do conhecimento numa perspectiva que transita de um paradigma Probabilístico para um Possibilístico.

Tal ilustração inicia com o pressuposto da existência de constructos capazes de representar uma ontologia que especifique o conhecimento de um domínio com incertezas manifestadas por aleatoriedade e imprecisão. Esta etapa é apenas argumentativa e enaltece o interesse da Engenharia de Ontologias na construção desta abordagem de representação do conhecimento conforme proposto por Brignoli, Sell e Gauthier (2011), não interferindo no objetivo essencial da pesquisa que é fornecer a abordagem híbrida no tratamento do conhecimento sobre incertezas, no caso, sendo mais específico, no processo de diagnóstico clínico.

De qualquer modo é importante exprimir os requisitos mínimos necessários que atendam ao nível de *conceitualização* da ontologia, conforme já elucidado na Revisão da Literatura quando Rautenberg *et al.* (2010) propõe os artefatos de documentação da ferramenta *ontoKEM*. Seguindo minimamente as recomendações do autor, sugere-se que a ontologia estocástica suposta na figura 28 disponha dos seguintes elementos necessários a um processo de conversão, representação e inferência por parte do modelo de inferência fuzzy-bayesiano que aqui se propõe:



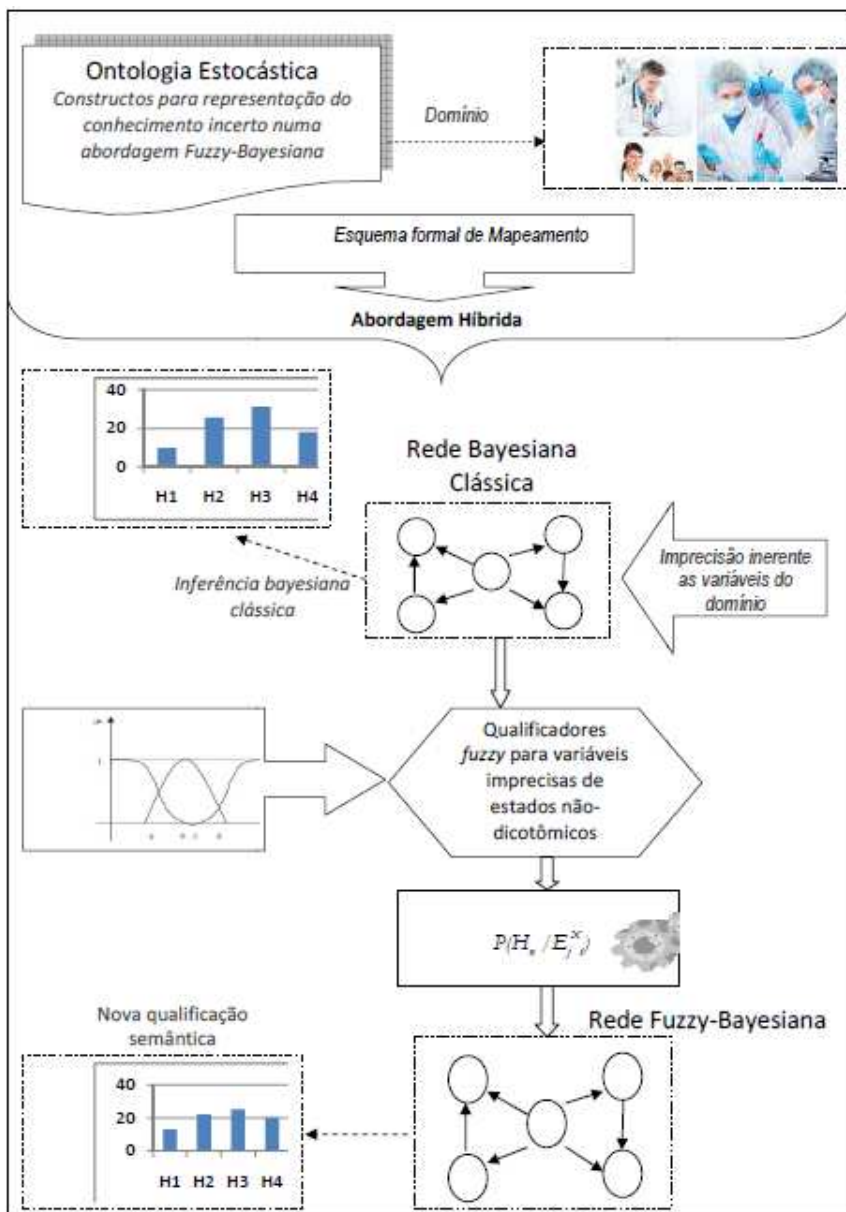


Figura 28 – Perspectiva de qualificação do conhecimento incerto
 Fonte: (do autor)

H_i = nodo que representa a saída da rede (Hipóteses diagnósticas, CLASSIFICAÇÃO)

E_j = nodos que representam as entradas a rede (evidências apresentadas, eventos observados)

Estrutura do nodo H_i:	
<ul style="list-style-type: none"> ▪ identificação ▪ estados: 	<ul style="list-style-type: none"> ○ identificação ○ probabilidade <i>a priori</i>
Restrição: Soma $P(H_i) = 1$	
Estrutura de cada nodo E_j:	
<ul style="list-style-type: none"> ▪ identificação ▪ tipo (Crisp = Discreto OU Fuzzy = Contínuo) 	
Restrição: se tipo = Fuzzy, definir:	
	<ul style="list-style-type: none"> • suporte da variável linguística E_j
<ul style="list-style-type: none"> ▪ estados: 	<ul style="list-style-type: none"> ○ identificação ○ probabilidade Condicional, $P(E_j/H_i)$ ○ parâmetro de qualificação:
Restrição:	
	<ul style="list-style-type: none"> ▪ se tipo = Crisp \rightarrow parâmetro = 1 ▪ se tipo = Fuzzy, definir:
	<ul style="list-style-type: none"> • valor mínimo • valor máximo • função de pertinência
	} Suporte
parâmetros:	
	<ul style="list-style-type: none"> ▪ lineares ▪ Não-lineares
	<ul style="list-style-type: none"> ○ valor de entrada (observado)

Em termos práticos, na concepção do modelo lógico e físico, estes requisitos podem ser incorporados ao esquema sintático de linguagens de especificação de ontologias, numa forma similar às anotações probabilísticas inseridas nos esquemas *PR-OWL*, *Bayes-OWL* e *Fuzzy Ontology*, referenciados anteriormente.

Esta conjectura não mais será explorada nesta pesquisa, mas, sugerida em futuros trabalhos. Para a continuidade da modelagem e para toda afirmação acerca do uso das Redes Fuzzy-Bayesianas em suporte a inferência sobre ontologias estocásticas, pressupõe-se a existência dos constructos segundo os requisitos necessários.

Retomando a figura 28 é propenso refletir sobre a nova qualificação semântica produzida pela distribuição das probabilidades inferidas pelo modelo fuzzy-bayesiano e averiguar respostas aos seguintes questionamentos:

- i) O fator imprecisão pode causar este efeito de redistribuição ou “*espalhamento*” da distribuição das probabilidades de uma Rede Bayesiana?
- ii) Pode existir alguma relação entre entropia e o processo de raciocínio da Rede Bayesiana sobre variáveis imprecisas?
- iii) Se confirmadas às questões (i) e (ii) no que isso acarreta em termos da semântica da Rede Bayesiana como estrutura de representação do conhecimento para suporte a um processo decisório, como exemplo, em diagnóstico de Risco Metabólico de crianças e adolescentes?
- iv) Se negada à questão (ii) então qual a dinâmica percebida na distribuição das novas probabilidades influenciadas pela imprecisão?

Almeja-se que a expectativa a estas questões cessarão a partir da validação do modelo mediante os dados disponibilizados em planilhas de prontuários, bem como da base de conhecimento já utilizada por uma Rede Bayesiana Clássica.

3.2 O modelo

A elaboração do modelo proposto seguirá uma especificação abrangente e genérica, em princípio, parcialmente desprovida dos limites que circundam a problemática da Classificação do Risco Metabólico em crianças e adolescentes. Contudo, durante o desenvolvimento da modelagem fica perceptível a inserção gradual de parâmetros associados às especificidades do domínio.

Suponhamos a existência de um cenário fictício de representação do conhecimento sobre um domínio específico no âmbito do processo de diagnóstico clínico, o qual apresenta as variáveis e suas relações por meio de uma Rede Bayesiana, considerando-se o fato de que o conhecimento intrínseco nas relações está associado a incertezas. O grafo da figura 29 a

seguir mostra a Rede Bayesiana, em uma estrutura *Naive Bayes*, cujo nodo ascendente é denotado por H_i ($i=1..n$) sendo o vetor das Hipóteses Diagnósticas a serem consideradas no conhecimento da Rede e os nodos descendentes são denotados por E_j ($j=1..m$), que são as evidências observadas.

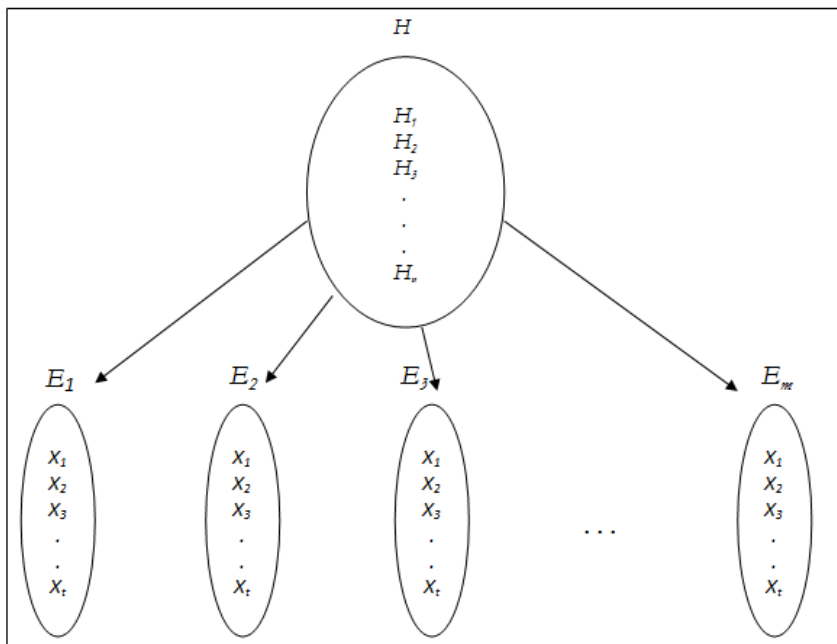


Figura 29 – Grafo da representação genérica de uma Rede Bayesiana com estrutura *Naive Bayes*

Fonte: (do autor)

É conveniente ressaltar que o cenário acima ilustra uma Rede Bayesiana com a representação de variáveis de estados discretos.

O diagrama mostra que a variável H pode conter até n estados discretos e a distribuição das probabilidades vinculadas a estes estados propagam em função da relação causal entre H_i e suas variáveis descendentes E_j . Nota-se que podemos representar m variáveis descendentes e cada uma pode conter até t estados discretos.

Numa Rede Bayesiana a distribuição das probabilidades de H_i em função das evidências E_j observadas é calculada por meio da aplicação do Teorema de Bayes, denotado neste caso por:

$$P(H_i|E_j) = \frac{P(E_j|H_i) \cdot P(H_i)}{P(E_j)} \quad \text{Eq. (23)}$$

Para inferir sobre as relações de causalidade entre H_i e E_j é necessária, por meio de um trabalho junto ao especialista no domínio em questão, a obtenção das *CPTs* (*Conditional Probability Table*).

Suponhamos então a especificação das probabilidades *a priori* sobre a variável H e seus estados discretos:

Tabela 4 – Estrutura de um vetor de Hipóteses Diagnósticas e suas probabilidades

H_i	$P(H_i)$
H_1	$P(H_1)$
H_2	$P(H_2)$
H_3	$P(H_3)$
.	.
.	.
.	.
H_n	$P(H_n)$

(Fonte: do autor)

Também, a especificação das probabilidades condicionais $P(E_j/H_i)$:

Tabela 5 – Estrutura geral de uma *CPT*

$P(E_j/H_i)$ ($j=1..m$)	H_1	H_2	H_3	...	H_n
x_k ($k=1..t$)					
x_1	$P(E_{j^x_1} H_1)$	$P(E_{j^x_1} H_2)$	$P(E_{j^x_1} H_3)$...	$P(E_{j^x_1} H_n)$
x_2	$P(E_{j^x_2} H_1)$	$P(E_{j^x_2} H_2)$	$P(E_{j^x_2} H_3)$...	$P(E_{j^x_2} H_n)$
x_3	$P(E_{j^x_3} H_1)$	$P(E_{j^x_3} H_2)$	$P(E_{j^x_3} H_3)$...	$P(E_{j^x_3} H_n)$
.
.
.
x_t	$P(E_{j^x_t} H_1)$	$P(E_{j^x_t} H_2)$	$P(E_{j^x_t} H_3)$...	$P(E_{j^x_t} H_n)$

Fonte: (do autor)

Obviamente, a tabela acima denota características multidimensionais para representar tais probabilidades, porém, esta é uma questão que envolve aspectos computacionais de representação de uma estrutura de dados, não

sendo o foco e tão pouco essencial para a elucidação da proposta deste trabalho.

As notações da tabela propõem que $P(E_j \times_i | H_n)$ seja a probabilidade ou a crença que se manifesta na relação entre o estado \times_k ($k=1..t$ estados) da variável E_j ($j=1..m$) e a confirmação da hipótese H_i ($i=1..n$).

Após a propagação resultante do cálculo das probabilidades condicionais a Rede Bayesiana representará o conhecimento relativo ao raciocínio sobre incertezas num cenário de relações de aleatoriedade sobre as variáveis.

Para exemplificar, suponha que H_i tenha cinco estados discretos e a partir da propagação das probabilidades e suas relações com E_j as probabilidades ou o conhecimento sobre a confirmação das hipóteses resulte na seguinte distribuição conforme a figura 30:




Figura 30 – Distribuição das probabilidades da saída H após a propagação
Fonte: (do autor)

Observado o gráfico acima suponha que H_3 seja a manifestação clínica da confirmação de um infarto do miocárdio com $P(H_i | E_j) > 30\%$ dadas às evidências de que o paciente é fumante, consome gordura, tem uma atividade física irregular, entre outras possíveis relações de causalidade entre infarto do miocárdio e estilo ou qualidade de vida. Neste caso, é fundamental compreender que a inferência realizada neste domínio considerou a confirmação ou não das evidências, ou seja, *paciente_fumante=sim* ou *paciente_fumante=não*, da mesma forma que, *paciente_consome_gordura = sim* ou *paciente_consome_gordura = não*, desta forma, a certeza na observação é indicada por um estado booleano, binário ou ainda conhecido como estado em uma variável Crisp.

Sabemos que no mundo real, muitos fenômenos não ocorrem de maneira *booleana* e que nem tudo pode ser explicado e modelado por meio de sistemas bivalentes. Deve ser considerado o fato de que muitos conceitos e relações se definem de maneira vaga, ambígua, subjetiva, cujos significados denotam imprecisão. Para a ilustração fictícia anterior podemos considerar, sim, que um paciente consome gordura, ou seja, do ponto de vista probabilístico, o fato está confirmado, logo, a *Crença(fato)*=1. Contudo, num cenário possibilístico, poder-se-ia levar em consideração que o fenômeno “*consumir gordura*” manifesta uma variável contínua com estados difusos, tais como: o paciente consome (*pouquíssima* ou *pouca* ou, *razoável* ou *considerável*, ou *muita* ou *elevadíssima*) quantidade de gordura. É perceptível, neste caso, a sobreposição semântica entre os termos, caracterizada pela incerteza dada por imprecisão.

Desta forma, pretende-se argumentar sobre a hipótese das variáveis descendentes E_j mudarem de estados discretos para contínuos, ou seja, quando observado a sobreposição e imprecisão entre os conceitos associados aos estados x_k . Esta proposta então converge para uma consideração acerca da manifestação semântica sobre o conhecimento da Rede Bayesiana representado por uma distribuição de probabilidades ajustadas pela imprecisão inerente às variáveis no domínio. Trata-se supostamente de uma qualificação probabilística em função da subjetividade nos conceitos ou relações representadas pelas variáveis do domínio. A contribuição desta formulação incrementará os aspectos funcionais das Redes Fuzzy-Bayesianas e, naturalmente, uma nova perspectiva em termos da qualidade semântica do conhecimento inferido no domínio em discussão.

É importante lembrar que o objetivo essencial deste trabalho é fornecer uma nova perspectiva para a análise do conhecimento sobre incertezas em Redes Fuzzy-Bayesianas com variáveis de estados não-dicotômicos. É sugestiva que a solução em seu modelo possa ser uma alternativa acoplável a metodologias e ferramentas voltadas a projeção de Sistemas de Conhecimento (ex: *CommonKADS*) em que a tarefa e o conhecimento modelado são pertinentes a um cenário com variáveis caracterizadas por incertezas.

A partir deste ponto, a etapa de modelagem perpassa por uma redefinição do formalismo matemático que propicia o cálculo das probabilidades condicionais e da propagação do conhecimento na Rede Bayesiana. Assim sendo, se faz necessária a retomada do modelo de inferência especificado pelo Teorema de Bayes e suas devidas alterações na fórmula de modo a permitir que uma nova propagação seja realizada sobre a influência de variáveis contínuas imprecisas.

Partimos da formulação básica do Teorema de Bayes e denotamos algumas modificações em sua forma primitiva para permitir o entendimento da indução proposta.

Para melhor esclarecimento acerca do processo de construção e especificação do modelo proposto é oportuno elucidar o significado do termo *indução* no contexto da formalização matemática desta pesquisa. Portanto, indução aqui refere-se ao método de prova matemática aplicado sobre um conjunto de dados discretos com o objetivo de demonstrar que um enunciado é verdadeiro, partindo da verificação de sua validade para $n=1$, $n=k$ e conseqüentemente para $n=k+1$, onde $n \in \mathbb{Z}$ (ROSEN, 2009).

Desde já é importante ressaltar que esta construção pretende finalizar com um modelo matemático de inferência amplo o suficiente para considerar a representação de uma Rede Fuzzy-Bayesiana com n variáveis de entrada (E) e uma variável de saída (H) (estrutura *Naive Bayes* de classificação), além de considerar que cada variável E poderá conter múltiplos estados, discretos ou contínuos. A equação (24) especifica o Teorema de Bayes e a notação inicial:

$$P(H_i | E_j x_k) = \frac{P(E_j x_k | H_i) \cdot P(H_i)}{P(E_j x_k)} \quad \text{Eq. (24)}$$

Mapeamento
Probabilístico \leftrightarrow Possibilístico

$$\tilde{P} = f\left(P(H_i | E_j x_k)\right) \quad (k = 1 \dots t \text{ estados})$$

Função de qualificação do
raciocinador Fuzzy-Bayesiano

A priori, assumiremos \tilde{P} como sendo o vetor das probabilidades de H_i ajustadas pela imprecisão sobre as variáveis E_j de estados contínuos x_k . Para fins de identificação, denotaremos \tilde{P} como *probabilidade sobre evidências imprecisas*.

A consideração sobre a imprecisão inerente às variáveis do domínio será modelada por meio de um ajuste matemático que se fará nos coeficientes que representam as probabilidades dos estados x_k , discretos ou contínuos de cada variável de entrada (*input*) E_j da Rede Bayesiana. Utilizaremos a estrutura e a funcionalidade do processo de fuzzificação oriundo das técnicas aplicadas em Lógica Fuzzy para obter os fatores de ajuste da imprecisão da Rede conforme o objetivo da pesquisa.

Suponhamos que E_j seja uma variável de entrada que apresente estados x_k imprecisos, logo esta imprecisão pode ser especificada por um intervalo real S^{E_j} , como sendo o suporte da variável E_j compreendido entre $S^{E_j}_{min}$ e $S^{E_j}_{max}$. O número de estados imprecisos x_k também determinará a quantidade de conjuntos fuzzy que constituirão a extensão da variável E_j e que de uma maneira geral pode ser observado conforme ilustra a figura 31:

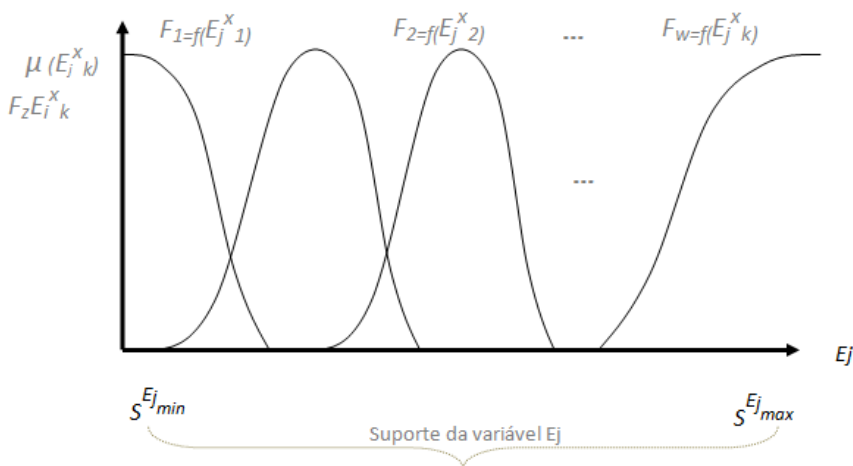


Figura 31 – Distribuição dos estados fuzzy de uma evidência imprecisa

Fonte: (do autor)

Nota-se na figura anterior que as funções ilustradas são *não-lineares*, contudo, de acordo com a Teoria da Lógica Fuzzy, a escolha da função que representará o conjunto difuso modelado dependerá muito das características reais da variável observada pelo modelador ou especialista no domínio. Portanto, a escolha da forma gráfica e funcional do conjunto difuso não interfere na forma indutiva da especificação do modelo

matemático desta pesquisa. O quadro 4 sugere o significado de alguns elementos constituintes desta especificação:

$F_z E_j^x$	Denote a função que modela a imprecisão do estado x_k da variável E_j , podendo ter $z=1\dots w$ (estados fuzzy);
$\mu(E_j^x)$ $F_z E_j^x$	Retorne o <i>grau de pertinência</i> do estado x_k da variável E_j em relação ao conjunto fuzzy F_z . Este fator terá papel fundamental no processo de propagação das probabilidades da Rede Bayesiana sob a sua nova perspectiva semântica em conformidade com o conhecimento do especialista do domínio;
$\mu(E_j^x)$ $F_z E_j^x$	$= \begin{cases} 1, & \text{se } E_j \text{ é Crisp} \\ F_z(E_j^x), & \text{se } E_j \text{ é Fuzzy } \forall \text{ entrada } \in \text{suporte de } F_z \\ 0, & \text{se } E_j \text{ é Fuzzy } \forall \text{ entrada } \notin \text{suporte de } F_z \end{cases}$

Quadro 4 – Elementos constituintes da especificação do modelo matemático-qualificadores fuzzy

Fonte: (do autor)

Para simplificar as notações matemáticas que seguem a indução proposta neste trabalho, utilizaremos $\mu(E_j^x)$ como sendo $\mu(E_j^x)$, que será o fator

$$F_z E_j^x$$

de ajuste da imprecisão das probabilidades da Rede Bayesiana, o qual também poder-se-á denominar de *Qualificador Difuso*.

3.2.1 Análise da modelagem sobre a imprecisão

Na continuidade do processo indutivo que especificará o modelo de raciocínio Fuzzy-Bayesiano far-se-á uma análise acerca da aceitabilidade desta abordagem que empregará Lógica Fuzzy na solução do problema da distribuição não dicotômica de estados de uma variável E_j .

Suponhamos que a variável E_j possua k estados entrelaçados conforme ilustrado pela figura 32:




Figura 32 – Superposição de estados difusos de uma evidência imprecisa

Fonte: (do autor)

Usualmente, a modelagem de conjuntos fuzzy especifica uma distribuição de estados sobrepostos de modo que uma determinada entrada $X=X_i$ implicará em, no máximo, dois valores de $\mu(x)$ relativos aos graus de pertinência, estabelecendo um formato dicotômico para as relações difusas. Tal observação induz a seguinte indagação:

Como é possível um valor de entrada $X=X_i$ pertencer a um número maior que dois estados conforme pressuposto pela figura acima?

A resposta pode ser justificada pelo denominado *Princípio da Superposição de Estados*, das fundamentações teóricas que estabelecem as leis da Física Quântica para os estudos dos Estados Quânticos, conforme descrito em capítulo anterior, segundo a revisão bibliográfica.

Utilizando-se da definição de Eisberg e Resnick (1985) e instanciando-a para o cenário da problemática desta pesquisa poderíamos ilustrar a seguinte situação: um indivíduo pode pertencer ao mesmo tempo a três estados de medição (classes) de obesidade, por exemplo: (*SOBREPESO, OBESO, OBESO GRAVE*).

O argumento para propor que os estados contínuos que descrevem a imprecisão das variáveis no cenário da Classificação de Risco Metabólico é compreender que estes estados podem ser teoricamente correspondentes aos estados quânticos $|\psi_i\rangle$.

Para refinar esta proposição recorremos a Salmeron (2007) com sua conceituação e expressividade matemática sobre o *Princípio da*

Superposição. Para o autor, de uma maneira geral, o estado de um sistema varia com o tempo. Como em termos quânticos, um estado é representado por uma função de onda $\psi(q,t)$ então esta função é dependente do tempo.

A obra de Salmeron (2007) mostra que se S é um sistema físico que pode existir tanto num estado de função de onda $\psi_1(q)$ como no estado de função de onda $\psi_2(q)$ então a medida de uma quantidade física f dá, por hipótese, o resultado f_1 com probabilidade $p = 1$ e, se estiver em $\psi_1(q)$ e, resulta f_2 também com probabilidade $p = 1$ se estiver em $\psi_2(q)$. Esta afirmativa postula que:

- 1) Toda função da forma $c_1 \psi_1 + c_2 \psi_2$, onde c_1 e c_2 são números complexos, é também um estado do sistema;
- 2) Neste estado, uma medida de f dará ou o resultado f_1 ou o resultado f_2 .

A proposição anterior fornece parâmetros condizentes e suficientes para instanciar este princípio para uma forma de *Superposição Conceitual*, agregada como postulado teórico da pesquisa. Sobre esta ótica poder-se-ia sugerir que os conceitos superpostos, de natureza subjetiva e vinculados à imprecisão das variáveis do domínio sendo representados por funções fuzzy são expressões que denotam a representação do conhecimento incerto, e este, pode ser a entidade física na forma de estado conceitual de um sistema S , neste caso, o sistema de Classificação de Risco Metabólico. A medida de uma quantidade física que Salmeron (2007) se refere pode ser a medida aferida ao paciente sobre as variáveis tratadas no domínio do problema da Classificação de Risco Metabólico.

Desta forma, considerando que as funções de pertinência fuzzy que descrevem os estados superpostos das variáveis associadas à imprecisão são representações correspondentes aos estados quânticos denotados por funções de onda, então é plausível que:

$$\begin{aligned}
 |\psi_1\rangle &\equiv F_z E_j^x{}_1 \\
 |\psi_2\rangle &\equiv F_z E_j^x{}_2 \\
 |\psi_3\rangle &\equiv F_z E_j^x{}_3 \\
 &\dots \\
 |\psi_k\rangle &\equiv F_z E_j^x{}_k
 \end{aligned}
 \tag{Eq. (25)}$$

Logo, um novo estado resultante da *superposição* de k estados poderia ser denotado por:

$$|\psi_{novo}\rangle = \int_1^k F_z E_j^x \delta F_z \quad \text{Eq. (26)}$$

pois $|\psi_{novo}\rangle = |\psi_1\rangle + |\psi_2\rangle + |\psi_3\rangle + \dots + |\psi_k\rangle$

A integral definida da equação (26) denota o processo de *Junção* de múltiplos estados superpostos gerando um novo estado a ser considerado. Este novo estado é resultante de um colapso, conforme estabelece Eisberg e Resnick (1985). Entretanto, o modelo desenvolvido nesta tese não emprega de maneira exaustiva este princípio em sua conjectura matemática. Neste caso, o fenômeno da incerteza pela imprecisão adere a uma contribuição maior da própria aplicação da Teoria dos Conjuntos Fuzzy.

3.2.2 Indução ao raciocinador Fuzzy-Bayesiano não-dicotômico

Retomemos a equação (23) que especifica a forma geral do Teorema de Bayes para permitir a realização de inferências probabilísticas sobre domínios com variáveis totalmente Crisp. Propor-se o ajuste desta forma de inferência para que seja considerada a imprecisão das evidências apresentadas à Rede Bayesiana e associadas ao valor de probabilidade dos estados x_k das variáveis E_j .

Consideraremos inicialmente que $i=2$, $j=1$ e $k=2$, ou seja, uma Rede Bayesiana com dois estados na variável de saída H e dois estados em uma só evidência E apresentada. Desta forma teremos:

$$\tilde{P}(H_i | E_1 x_k) = \frac{[P(E_1 x_1 | H_i) \cdot (\varepsilon_1^E x_1)^{+P(E_1 x_2 | H_i) \cdot (\varepsilon_1^E x_2)}] \cdot P(H_i)}{P(E_1 x_k)} \quad \text{Eq. (27)}$$

onde,

$$\begin{aligned}
 P(\mathbf{E}_1 \mathbf{x}_k) = & \\
 & \left\{ \left[P(\mathbf{E}_1 \mathbf{x}_1 | \mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_1^E \mathbf{x}_1) + \right. \right. \\
 & \left. \left. P(\mathbf{E}_1 \mathbf{x}_2 | \mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_1^E \mathbf{x}_2) \right] \cdot P(\mathbf{H}_i) \right\} + \\
 & \left\{ \left[P(\mathbf{E}_1 \mathbf{x}_1 | \neg \mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_1^E \mathbf{x}_1) + \right. \right. \\
 & \left. \left. P(\mathbf{E}_1 \mathbf{x}_2 | \neg \mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_1^E \mathbf{x}_2) \right] \cdot P(\neg \mathbf{H}_i) \right\}
 \end{aligned} \tag{Eq. (28)}$$

Neste caso, como $i=2$, ou seja, a variável de saída apresenta somente dois estados, é notório que $H_i = \{H_1, H_2\}$, logo, se $P(H_i) = P(H_1)$, então $\neg P(H_i) = P(H_2)$ e vice-versa.

Continuando a construção do modelo matemático que definirá a forma algébrica do raciocinador Fuzzy-Bayesiano de modo indutivo, suponhamos que a estrutura da Rede Bayesiana contenha a saída $H_i = \{H_1, H_2, \dots, H_n\}$ e que as evidências apresentadas são $E_j = \{E_1, E_2\}$ com $k=1..t$ estados cada uma. Em consonância com a forma primitiva do Teorema de Bayes e com a incorporação de ajuste de imprecisão, podemos propor que:

$$\begin{aligned}
 \tilde{P}(\mathbf{H}_i | \mathbf{E}_1 \mathbf{x}_k \cap \mathbf{E}_2 \mathbf{x}_k) = & \tag{Eq. (29)} \\
 & \left\{ \left[\begin{array}{c} P(\mathbf{E}_1 \mathbf{x}_1 | \mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_1^E \mathbf{x}_1) + P(\mathbf{E}_1 \mathbf{x}_2 | \mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_1^E \mathbf{x}_2) + \dots \\ \dots + P(\mathbf{E}_1 \mathbf{x}_t | \mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_1^E \mathbf{x}_t) \end{array} \right] \cdot \left[\begin{array}{c} P(\mathbf{E}_2 \mathbf{x}_1 | \mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_2^E \mathbf{x}_1) + P(\mathbf{E}_2 \mathbf{x}_2 | \mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_2^E \mathbf{x}_2) + \dots \\ \dots + P(\mathbf{E}_2 \mathbf{x}_t | \mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_2^E \mathbf{x}_t) \end{array} \right] \right\} \\
 & \frac{P(\mathbf{H}_i)}{P(\mathbf{E}_1 \mathbf{x}_k \cap \mathbf{E}_2 \mathbf{x}_k)}
 \end{aligned}$$

onde,

$$\begin{aligned}
 P(E_1 \mathbf{x}_k \cap E_2 \mathbf{x}_k) = & \hspace{15em} \text{Eq. (30)} \\
 & \left\{ \left(\left[\begin{array}{l} P(E_1 \mathbf{x}_1 | \mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_1^E \mathbf{x}_1) + P(E_1 \mathbf{x}_2 | \mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_1^E \mathbf{x}_2) + \dots \\ \dots + P(E_1 \mathbf{x}_t | \mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_1^E \mathbf{x}_t) \end{array} \right] \cdot P(\mathbf{H}_i) \right) + \right. \\
 & \left. \left(\left[\begin{array}{l} P(E_2 \mathbf{x}_1 | \mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_2^E \mathbf{x}_1) + P(E_2 \mathbf{x}_2 | \mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_2^E \mathbf{x}_2) + \dots \\ \dots + P(E_2 \mathbf{x}_t | \mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_2^E \mathbf{x}_t) \end{array} \right] \right) \right\} + \\
 & \left\{ \left(\left[\begin{array}{l} P(E_1 \mathbf{x}_1 | -\mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_1^E \mathbf{x}_1) + P(E_1 \mathbf{x}_2 | -\mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_1^E \mathbf{x}_2) + \dots \\ \dots + P(E_1 \mathbf{x}_t | -\mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_1^E \mathbf{x}_t) \end{array} \right] \cdot P(-\mathbf{H}_i) \right) + \right. \\
 & \left. \left(\left[\begin{array}{l} P(E_2 \mathbf{x}_1 | -\mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_2^E \mathbf{x}_1) + P(E_2 \mathbf{x}_2 | -\mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_2^E \mathbf{x}_2) + \dots \\ \dots + P(E_2 \mathbf{x}_t | -\mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_2^E \mathbf{x}_t) \end{array} \right] \right) \right\}
 \end{aligned}$$

Agora, estendendo o modelo para suportar $E_j = \{E_1, E_2, \dots, E_m\}$ teremos:

$$\begin{aligned}
 \tilde{P}(\mathbf{H}_i | E_1 \mathbf{x}_k \cap E_2 \mathbf{x}_k \cap \dots \cap E_m \mathbf{x}_k) = & \hspace{15em} \text{Eq. (31)} \\
 & \frac{[P(E_1 \mathbf{x}_1 | \mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_1^E \mathbf{x}_1) + P(E_1 \mathbf{x}_2 | \mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_1^E \mathbf{x}_2) + \dots + P(E_1 \mathbf{x}_t | \mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_1^E \mathbf{x}_t)] \cdot \\
 & [P(E_2 \mathbf{x}_1 | \mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_2^E \mathbf{x}_1) + P(E_2 \mathbf{x}_2 | \mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_2^E \mathbf{x}_2) + \dots + P(E_2 \mathbf{x}_t | \mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_2^E \mathbf{x}_t)] \cdot \\
 & \quad \vdots \\
 & [P(E_m \mathbf{x}_1 | \mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_m^E \mathbf{x}_1) + P(E_m \mathbf{x}_2 | \mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_m^E \mathbf{x}_2) + \dots + P(E_m \mathbf{x}_t | \mathbf{H}_i) \cdot (\boldsymbol{\varepsilon}_m^E \mathbf{x}_t)] \cdot P(\mathbf{H}_i)}{P(E_1 \mathbf{x}_k \cap E_2 \mathbf{x}_k \cap \dots \cap E_m \mathbf{x}_k)}
 \end{aligned}$$

onde,

$$\begin{aligned}
 P(E_1 x_k \cap E_2 x_k \cap \dots \cap E_m x_k) = & \quad \text{Eq. (32)} \\
 & \left\{ \begin{array}{l} \left[P(E_1 x_1 | H_i) \cdot (\varepsilon_1^E x_1) + P(E_1 x_2 | H_i) \cdot (\varepsilon_1^E x_2) + \dots \right. \\ \quad \left. \dots + P(E_1 x_t | H_i) \cdot (\varepsilon_1^E x_t) \right] \cdot \\ \left[P(E_2 x_1 | H_i) \cdot (\varepsilon_2^E x_1) + P(E_2 x_2 | H_i) \cdot (\varepsilon_2^E x_2) + \dots \right. \\ \quad \left. \dots + P(E_2 x_t | H_i) \cdot (\varepsilon_2^E x_t) \right] \cdot \\ \vdots \\ \left[P(E_m x_1 | H_i) \cdot (\varepsilon_m^E x_1) + P(E_m x_2 | H_i) \cdot (\varepsilon_m^E x_2) + \dots \right. \\ \quad \left. \dots + P(E_m x_t | H_i) \cdot (\varepsilon_m^E x_t) \right] \cdot P(H_i) \end{array} \right\} + \\
 & \left\{ \begin{array}{l} \left[P(E_1 x_1 | \neg H_i) \cdot (\varepsilon_1^E x_1) + P(E_1 x_2 | \neg H_i) \cdot (\varepsilon_1^E x_2) + \dots \right. \\ \quad \left. \dots + P(E_1 x_t | \neg H_i) \cdot (\varepsilon_1^E x_t) \right] \cdot \\ \left[P(E_2 x_1 | \neg H_i) \cdot (\varepsilon_2^E x_1) + P(E_2 x_2 | \neg H_i) \cdot (\varepsilon_2^E x_2) + \dots \right. \\ \quad \left. \dots + P(E_2 x_t | \neg H_i) \cdot (\varepsilon_2^E x_t) \right] \cdot \\ \vdots \\ \left[P(E_m x_1 | \neg H_i) \cdot (\varepsilon_m^E x_1) + P(E_m x_2 | \neg H_i) \cdot (\varepsilon_m^E x_2) + \dots \right. \\ \quad \left. \dots + P(E_m x_t | \neg H_i) \cdot (\varepsilon_m^E x_t) \right] \cdot P(\neg H_i) \end{array} \right\}
 \end{aligned}$$

Tomando as bases estabelecidas nas equações (27), (29) e (31) podemos agora especificar, de modo generalizado, o **Raciocinador Fuzzy-Bayesiano** que pode ser apresentado em sua forma reduzida e iterativa:

$$\tilde{P}(H_i | E_j x_k) = \frac{P(H_i) \cdot \prod_{j=1}^m \sum_{k=1}^t P(E_j x_k | H_i) \cdot (\varepsilon_j^E x_k)}{\sum_{i=1}^n P(H_i) \cdot \prod_{j=1}^m \sum_{k=1}^t P(E_j x_k | H_i) \cdot (\varepsilon_j^E x_k)} \quad \text{Eq. (33)}$$

Esta última equação define o que afirmamos ser o *kernel* da contribuição realizada pela tese e denominaremos de **Modelo de inferência Fuzzy-Bayesiano para variáveis não-dicotômicas**.

Conforme já elucidado, as variáveis de entrada da Rede denotadas por E_j ($j=1..m$) podem ser de natureza *discreta* (CRISP) ou *contínua* (Fuzzy). Logo, a propagação das probabilidades fuzzy-bayesianas dada pela aplicação do raciocinador inerente a função pode ser compreendida pela seguinte ilustração:

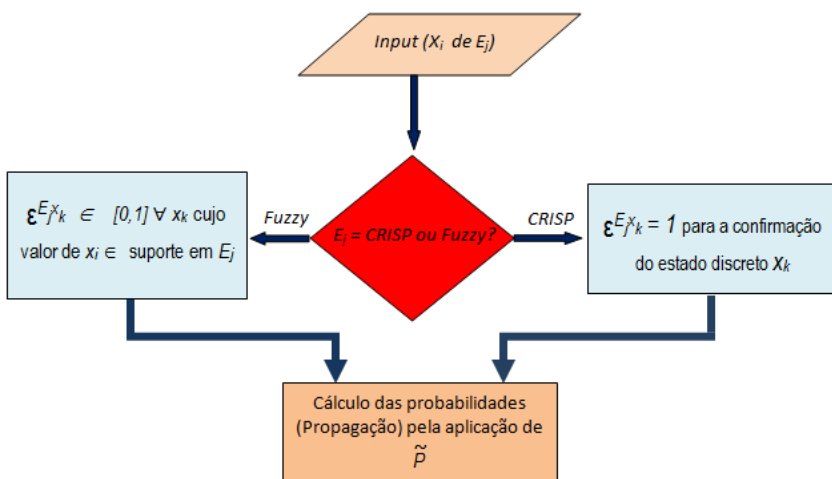


Figura 33 – Fluxograma da atribuição CRISP ou Fuzzy sobre as variáveis de entrada

Fonte: (do autor)

Apesar das premissas fundamentais terem sido motivadas pela demanda da problemática do raciocínio médico sobre incertezas, cabe salientar que a equação (33) pode ser instanciada para outros domínios conforme suas demandas de interesse. Como exemplo, em Penz (2011) o autor recorreu a um modelo Fuzzy-Bayesiano de variáveis dicotômicas disponibilizado nos trabalhos de Brignoli (2001) e Tibiriçá (2005) para solucionar problema de aferição de desempenho no campo da pesquisa industrial com compressores.

Contudo, a formulação e a aplicabilidade do modelo disponibilizado respectivamente em Brignoli (2001) e Tibiriçá (2005) limitaram-se a uma Rede Bayesiana com nodos e variáveis de formato dicotômico.

A equação (33) estende-se a esta limitação e pode ser aplicada em Redes Bayesianas com múltiplos estados de formato não-dicotômico, logo, esta contradição à dicotomia elucidada em Brignoli (2001) e Tibiriçá (2005) é determinada por uma *junção* dos coeficientes de possibilidade vinculados às evidências imprecisas.

Na sequência será averiguada a eficácia ou a acurácia da equação (33) quando aplicada sobre uma base de conhecimento de domínio real no âmbito da atividade de diagnose em medicina.

Cabe nesta oportunidade enfatizar a contribuição interdisciplinar que caracteriza uma pesquisa desta conotação no campo da Engenharia do Conhecimento. As simulações e validações serão apreciadas pelas orientações e argumentações de especialista humano na área de medicina pediátrica.

3.3 Insumos do Conhecimento e a Verificação de Resultados

A unidade anterior apresentou a formulação matemática de um modelo de inferência que pode ser utilizado na implementação de mecanismos de raciocínio em Redes Fuzzy-Bayesianas.

O desenvolvimento da indução anterior fornece um modelo parametrizado de modo a suportar inferência em Redes Fuzzy-Bayesianas com múltiplas evidências e múltiplos estados. Pretende-se verificar resultados a partir da sua submissão a um contexto real em medicina pediátrica na classificação de Risco Metabólico, embora, pressupõe-se sua aplicabilidade em outros domínios com características de representação de conhecimento sobre incertezas.

3.3.1 Retomando a descrição do domínio

Nosso cenário de verificação reportará ao trabalho desenvolvido por Mayer (2012) que utilizou de um Sistema Especialista Bayesiano Clássico para validar uma Base de Conhecimento acerca da classificação do Risco Metabólico de crianças e adolescentes a partir de dados disponibilizados em prontuários.

Após o trabalho de coleta de dados e de modelagem das partes, qualitativa e quantitativa, realizada nos estudos de Mayer (2012), foi elaborada a Rede Bayesiana Clássica apresentada pela figura 34.

Os nodos que constituem o diagrama de representação da Rede Bayesiana da figura 34 denotam claramente a existência de variáveis do tipo CRISP, como é o caso do nodo que representa a variável –

Hereditariedade, pois seus estados são de natureza discreta e binária, ou seja, não é possível uma pessoa pertencer ao mesmo tempo a, pelo menos, dois estados desta variável, logo, como uma evidência de entrada ao processo de propagação das probabilidades de saída para a hipótese – Risco Metabólico, a variável – Hereditariedade não apresenta uma incerteza por imprecisão.

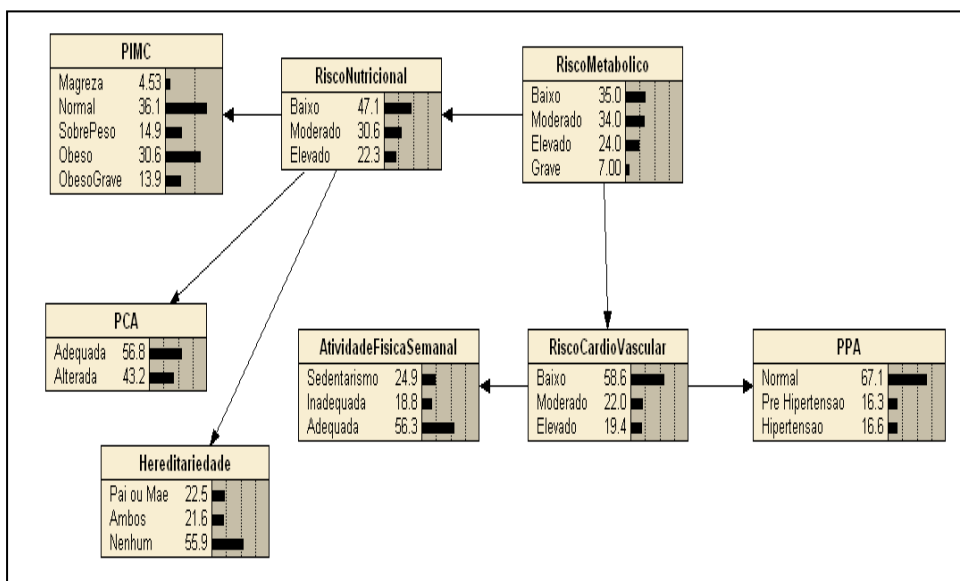


Figura 34 – Parte Qualitativa da Rede Bayesiana – estrutura hierárquica
Fonte: Nassar (2012)

Contudo, observa-se agora o nodo que representa a evidência PIMC (Perfil do Índice de Massa Corpórea) que denota uma variável de natureza subjetiva, cuja imprecisão intrínseca na rotulação dos seus estados contínuos sugere um tratamento mais detalhado em relação ao tipo de inferência que implicará na qualidade semântica do processo classificatório bayesiano.

É justamente este tipo de variável que torna o cenário acima um contexto real propício de aplicação do modelo de inferência Fuzzy-Bayesiano desenvolvido por esta tese.

Na discussão e análise dos resultados produzidos pela classificação da Rede Bayesiana Clássica, Mayer (2012) relata sobre a ineficiência e limitações deste tipo de abordagem para processos de diagnóstico ou

classificação bayesiana realizada por uma estrutura que inclui variáveis de estados difusos ou sobrepostos. O modelo de inferência bayesiana clássico não releva estas questões de subjetividade nem tão pouco considera que, mesmo num contexto estocástico probabilístico emergem variáveis com estados contínuos e transitórios e que nos casos com valores limítrofes o tipo de raciocínio empregado influenciará na qualidade semântica dos resultados.

3.3.2 A Rede Bayesiana com estrutura *Naive Bayes*

Com o objetivo de simplificar o cenário de verificação, opta-se por uma forma mais reduzida da Rede Bayesiana da figura 34 com a exclusão de algumas variáveis de modo a focar-se agora na seguinte representação:

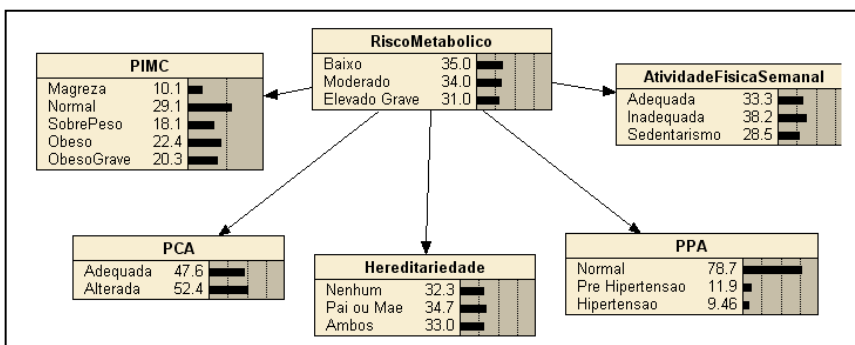


Figura 35 – Rede Bayesiana para Risco Metabólico – estrutura *Naive Bayes*
Fonte: Mayer (2012)

Nota-se uma Rede Bayesiana de estrutura *Naive Bayes* com 5 (cinco) variáveis de entrada (evidências) e uma variável de saída, ou seja, o vetor das hipóteses diagnósticas do Risco Metabólico.

É oportuno relatar que para a elaboração da Rede Bayesiana da figura 35 bem como para a obtenção das classificações a serem apreciadas pelo especialista humano, foi utilizado o software *Netica* (Norsys, 2012), ferramenta com distribuição de uma *versão livre* para um número limitado de nodos na construção do Diagrama da Rede Bayesiana.

O anexo A mostra a explicitação dos insumos (tabelas) utilizadas para compor a base de conhecimento probabilística que resultou na Rede Bayesiana Clássica da figura 35.

Sabe-se que o software *Netica Norsys* utiliza um raciocinador bayesiano clássico para propagar as probabilidades (conhecimento) da Rede Bayesiana, ou seja, todas as variáveis são de natureza CRISP.

Mostrar-se-á na sequência alguns resultados apontados pela variável – Risco Metabólico, para posteriormente poder-se confrontar estes resultados àqueles produzidos pela propagação fornecida pelo novo modelo de inferência apresentado neste trabalho, ou seja, o raciocinador Fuzzy-Bayesiano com variáveis não-dicotômicas.

Simulação 1:

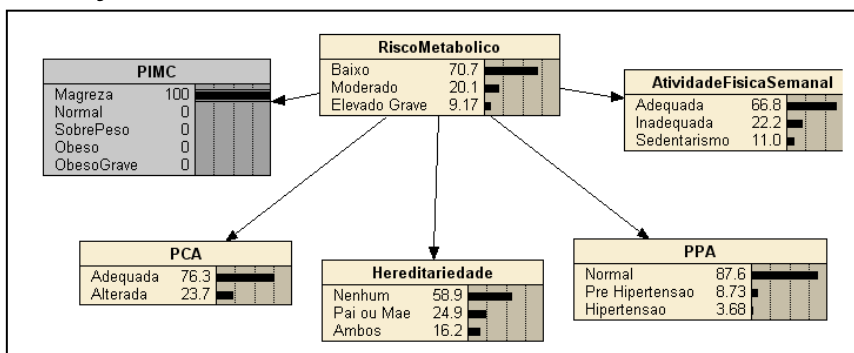


Figura 36 – Confirmação PIMC=Magreza
Fonte: Mayer (2012)

Nesta primeira simulação apresenta-se a confirmação da evidência PIMC com o estado = *Magreza*, logo, a saída produzida por $P(H_i|E)$ é mostrada pelas probabilidades elencadas nos estados da variável – Risco Metabólico.

Nota: observe que o somatório das probabilidades dos estados de cada variável da Rede equivale a 100%, ressaltando um pressuposto axiomático da Teoria da Probabilidade.

Simulação 2:

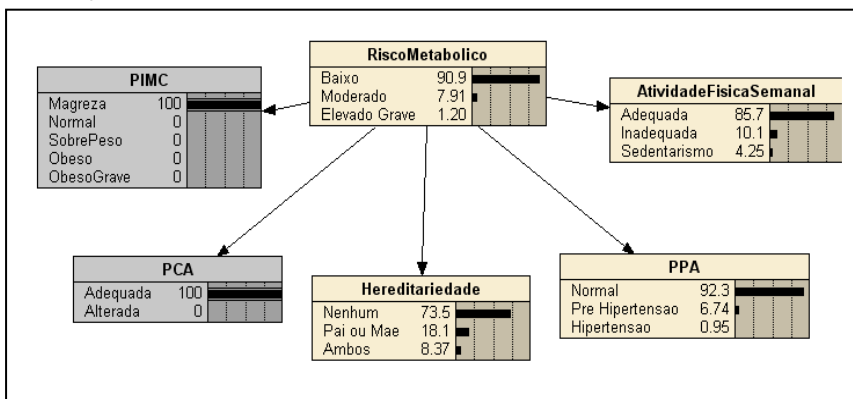


Figura 37 – Confirmação PIMC=Magreza e PCA=Adequada

Fonte: Mayer (2012)

Nesta simulação oferece-se a Rede Bayesiana a confirmação de duas evidências: o PIMC com estado = *Magreza* e o PCA (Perfil de Circunferência Abdominal) com estado = *Adequada*. Assim, as probabilidades do Risco Metabólico foram produzidas pela inferência sobre $P(H_i|E_1 \cap E_2)$.

Simulação 3:

A simulação seguinte utilizou de uma sequência de confirmações sobre a evidência PIMC em seus três últimos estados (*SobrePeso*, *Obeso*, *ObesoGrave*), mostradas, respectivamente pelas figuras 38, 39 e 40. Pretende-se com isso observar o comportamento das saídas probabilísticas em Risco Metabólico quando da mudança abrupta (CRISP) de estados de PIMC, embora, já argumentado que estes estados sugerem um refinamento mais difuso pela natureza da sobreposição conceitual que estes possuem.

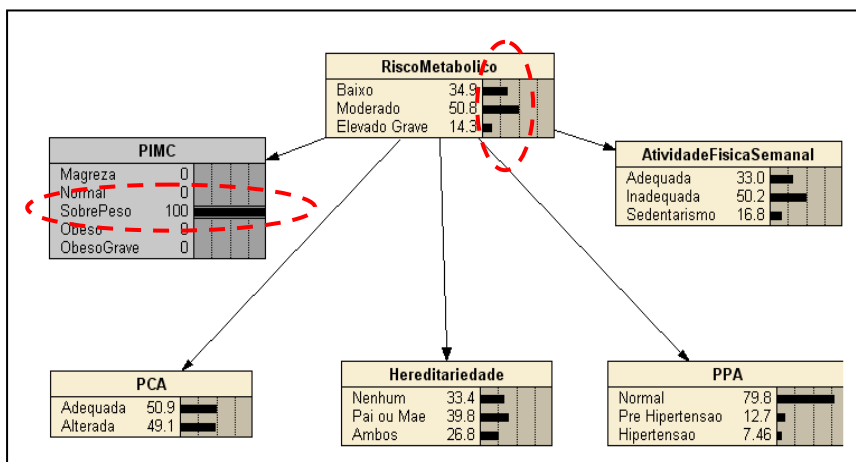


Figura 38 – Confirmação PIMC=SobrePeso
Fonte: Mayer (2012)

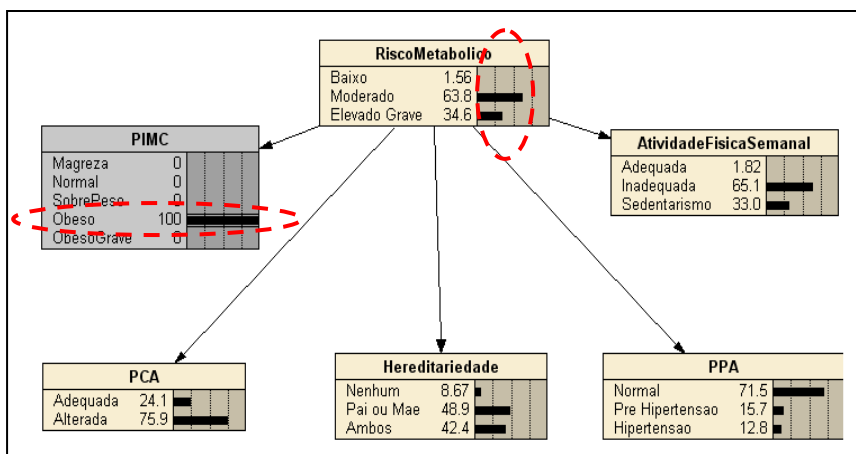


Figura 39 – Confirmação PIMC=Obeso
Fonte: Mayer (2012)

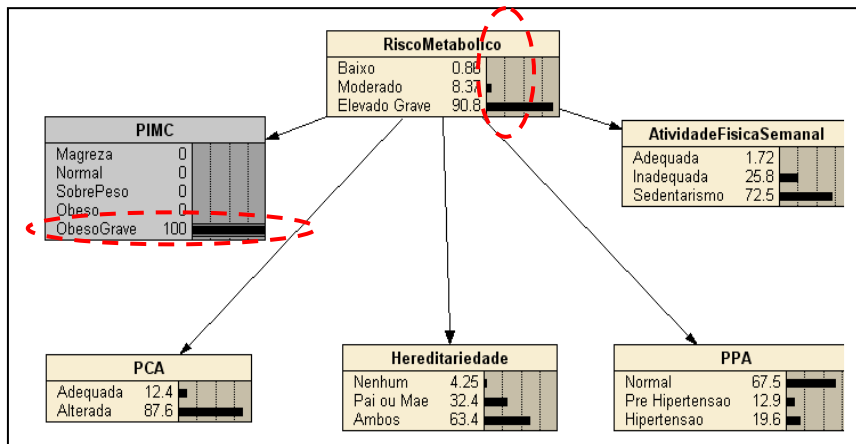


Figura 40 – Confirmação PIMC=ObesoGrave

Fonte: Mayer (2012)

Adiante mostrar-se-á que a situação acima ilustrada pode equivocar semanticamente o processo de suporte a decisão em diagnóstico médico dado o fato da forma de classificação utilizada para um cenário em que é perceptível a existência de transição gradual entre os estados confirmados pela evidência PIMC. Este cenário reforça a validade do argumento referenciado pelo *Princípio da Superposição de Estados*.

3.3.3 A Rede Fuzzy-Bayesiana: influências do fator imprecisão

Esta unidade apresentará a modelagem da imprecisão associada às variáveis de entrada (evidências) da Rede Bayesiana e serão simuladas novas propagações das probabilidades do vetor associado à variável - Risco Metabólico (saída) de modo a analisar o comportamento das distribuições de probabilidades do modelo Fuzzy-Bayesiano de estados não-dicotômicos (equação 33) em relação ao modelo clássico.

Serão focadas apenas as variáveis PIMC, PCA e AFS, suficientes para confrontarem-se as curvas de tendência das distribuições de probabilidades.

As simulações foram realizadas por meio da elaboração de planilhas construídas no MS-Excel com a flexibilização para a entrada dos dados disponibilizados pela base de conhecimento dos prontuários médicos do domínio em questão e também, para a manutenção de parâmetros necessários na conformação das funções de pertinência que modelam a

imprecisão intrínseca na conjectura de inferência. Os apêndices F, G e H mostram alguns extratos da planilha utilizada para as simulações.

Funções de Pertinência das variáveis Fuzzy:

1. PIMC (Perfil de Índice de Massa Corpórea)
Suporte = escore $z \in [-3,+3]$
Conjuntos Fuzzy: formas gaussianas e sigmóides
{Magreza, Normal, SobrePeso, Obeso, ObesoGrave}

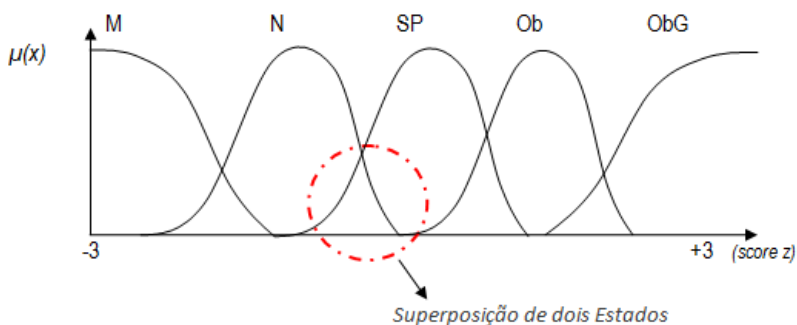


Figura 41 – Funções de pertinência para uma Superposição de dois estados em PIMC

Fonte: (do autor)

A figura 42 mostra extrato da planilha de suporte às simulações, neste caso, especificamente, a parametrização da variável linguística PIMC.

MODELAGEM DA IMPRECISÃO SOBRE AS EVIDÊNCIAS			
PIMC (Adolescentes)		<i>Entrada Xi--></i>	1
Suporte/E_i--> (Escore z) = [-3,+3]		Magreza	Normal
Parâmetros N-LINEARES			
a		2	-1
b		1	0,8
c		-2	1
d		1	
μ(Xi)		0,0	0,0
		<i>Sig. Inversa</i>	<i>GAUSS</i>

Figura 42 – Parametrização da variável linguística PIMC

Fonte: (do autor)

2. PCA (Perfil de Circunferência Abdominal)

Do mesmo modo que a variável anterior, PCA foi representada na sua forma linguística por duas funções de pertinência de formato sigmóide e com a mesma flexibilidade de parametrização.

3. AFS (Atividade Física Semanal)

Esta variável foi modelada de uma forma um pouco diferente em relação às duas anteriores. Para tal, ao invés de representá-la por Conjuntos Difusos, considerou-se que AFS pode ser representada como um Número Fuzzy.

O que motivou a elaboração de uma conjectura para representar AFS Fuzzy é o fato de esta variável possuir duas entradas – tempo de duração de uma atividade física e a frequência semanal em que um indivíduo pratica alguma atividade dentro deste tempo de duração. Conforme os valores para estas duas entradas, conclui-se que a AFS pode ser classificada como: *Sedentarismo*, *Inadequada* ou *Adequada*, que são os estados da variável probabilística AFS integrante da Rede Bayesiana mostrada na figura 35.

Para a representação do Número Fuzzy AFS foram utilizados parâmetros lineares, também com flexibilização para alterações por parte do especialista.

As simulações seguintes são realizadas para verificar resultados do modelo de inferência Fuzzy-Bayesiano desenvolvido por esta tese.

3.3.4 Verificação do Modelo aplicado sobre Dados

As simulações que seguem (4, 5, 6 e 7) objetivam a verificação dos resultados aplicada unicamente sobre dados, sem qualquer intervenção de especialista médico, averiguando-se em especial, aspectos mais relacionados à acurácia da conjectura matemática empregada na construção do modelo, identificando seu padrão comportamental em termos dos resultados numéricos gerados (saídas probabilísticas) e a aproximação ao padrão clássico.

Posteriormente, outras simulações terão o objetivo de realizar a comparação dos resultados obtidos pela inferência do especialista médico em contraposição àqueles obtidos pela inferência do modelo matemático, observando-se a análise descritiva do especialista médico em termos de seus critérios utilizados para apontar determinada classificação de Risco Metabólico.

Simulação 4:

As figuras 43 e 44 mostram, respectivamente:

- As distribuições de probabilidade da saída – Risco Metabólico, dada a confirmação da evidência PIMC na sua forma difusa, ou seja, a variável passa a ser considerada não mais na sua forma CRISP, mas, na composição de seus estados difusos e transitórios no intervalo de suporte mínimo e máximo considerado nos parâmetros de suas funções;
- As distribuições de probabilidade da saída – Risco Metabólico calculadas pela Rede Bayesiana Clássica, em conformidade com a simulação 1, figura 36.

PIMC (Fuzzy)			
ξ_i	P(Baixo/Pimc)	P(Moderado/Pimc)	P(ElevadoGrave/Pimc)
-3	0,709069855	0,205170436	0,085759708
-2,5	0,713127769	0,214258004	0,072614226
-2	0,71779682	0,224734275	0,057468906
-1,5	0,72025506	0,230441239	0,049303702
-1	0,720551144	0,232887026	0,046561829
-0,5	0,715453712	0,237188221	0,047358067
0	0,671479424	0,266794482	0,061726094
0,5	0,477201043	0,390769059	0,132029898
1	0,285320793	0,493224195	0,221455012
1,5	0,20257101	0,49846086	0,298968129
2	0,139653919	0,466062352	0,394283729
2,5	0,089958066	0,426303192	0,483738742
3	0,053687251	0,372995211	0,573317537




Figura 43 – Distribuição de Probabilidades para PIMC pela Rede Fuzzy-Bayesiana
Fonte: (do autor)




Figura 44 – Distribuição de Probabilidades para PIMC pela Rede Clássica
Fonte: (do autor)

Notas:

1. Nos resultados calculados pelo modelo Fuzzy-Bayesiano o somatório das probabilidades da saída – Risco Metabólico continua sendo igual a 1, confirmando e preservando a propriedade axiomática da Teoria da Probabilidade já elucidada em texto anterior;
2. As curvas de distribuição das probabilidades do modelo Fuzzy-Bayesiano apresentam padrão similar em suas tendências em relação à propagação clássica, embora, com a minimização do efeito de mudança abrupta, ou seja, as alterações são mais graduais em consonância com o grau de possibilidade verificado pelas funções de pertinência sobre os estados difusos das evidências com imprecisão;
3. Enquanto ocorre uma mudança abrupta em $P(\text{Risco=Baixo}|\text{Pimc=Normal}) = 72,2\%$ para $P(\text{Risco=Baixo}|\text{Pimc=SobrePeso})=34,9\%$, na classificação da Rede Bayesiana Clássica, o modelo Fuzzy-Bayesiano estende um pouco mais a sua distribuição dos valores de probabilidade sobre $P(Hi)$

(ver os pontos circulados nos gráficos), caracterizando a realização de uma forma de “raciocínio aproximado” sobre o intervalo que define a imprecisão da variável PIMC na transição dos estados – *Normal* para *SobrePeso*. Nos gráficos acima, este efeito é percebido também em outros pontos os quais ocorreram alterações abruptas nos limítrofes, ilustrado pelas linhas de tendência associadas aos valores de $P(H_i|E)$.

Simulação 5:

Esta simulação foi realizada com base na inferência fuzzy-bayesiana sobre duas variáveis conjuntas: PIMC e PCA. O objetivo é demonstrar a eficácia da equação (33) quando aplicada sobre múltiplas variáveis. Novamente, o referencial de comparação é a distribuição de probabilidades calculadas pela inferência bayesiana clássica mostrada pela figura 37 da simulação-2. Assim, as figuras, 45 e 46 mostram, respectivamente, a distribuição das probabilidades pelo método Fuzzy-Bayesiano e pela inferência clássica.




Figura 45 – Distribuição de Probabilidades para PIMC e PCA pela Rede Fuzzy-Bayesiana

Fonte: (do autor)




Figura 46 – Distribuição de Probabilidades para PIMC e PCA pela Rede Clássica
Fonte: (do autor)

Ao comparar-se o padrão de tendências das curvas que representam as distribuições das probabilidades fuzzy-bayesianas e as distribuições das probabilidades bayesianas clássicas ilustradas nas figuras acima, nota-se que apenas a linha de cor azul, representando $P(RiscoMetabólico=Baixo|PIMC \cap PCA)$, tem alta similaridade. Naturalmente, isso é justificado pela forma crescente de distribuição dos valores de entrada X_i (*score-z*) da variável linguística PIMC que são utilizados no processo de simulação. As linhas de cor, vermelha e verde, representando respectivamente, $P(RiscoMetabólico=Moderado|PIMC \cap PCA)$ e $P(RiscoMetabólico=ElevadoGrave|PIMC \cap PCA)$ apresentam padrão similar apenas em suas extremidades. Os “picos” mostrados nestas linhas da figura 46 são resultantes das alterações abruptas de valores de probabilidade causados pelo efeito da simulação numa forma de junção do tipo Produto Cartesiano PIMC x PCA, obviamente, em seus estados discretos. Este

efeito não ocorreu nas linhas da figura 45, pois as conjunções entre PIMC e PCA em sua forma difusa são de mudança gradual.

Simulação 6:

Nesta, observa-se as distribuições de probabilidade da variável - RiscoMetabólico associadas com a imprecisão inerente ao intervalo de transição dos estados difusos – *SobrePeso*, *Obeso* e *ObesoGrave* que caracterizam a já elucidada *Superposição de Estados*. O objetivo da simulação é verificar o método de inferência Fuzzy-Bayesiano em situações cujas entradas (evidências) apresentadas a Rede Bayesiana caracterizam-se por uma dinâmica inerente a evolução gradual nos estados das variáveis envolvidas na modelagem do domínio.

As figuras, 47 e 48 mostram, respectivamente, as distribuições de probabilidades fuzzy-bayesianas para o intervalo do suporte da variável linguística PIMC que denota esta Superposição para um número de estados $n > 2$ e, a distribuição das probabilidades da Rede Bayesiana Clássica, conforme mostrado na simulação-3.




Figura 47 – Distribuição de Probabilidades para PIMC em estados Superpostos
Fonte: (do autor)

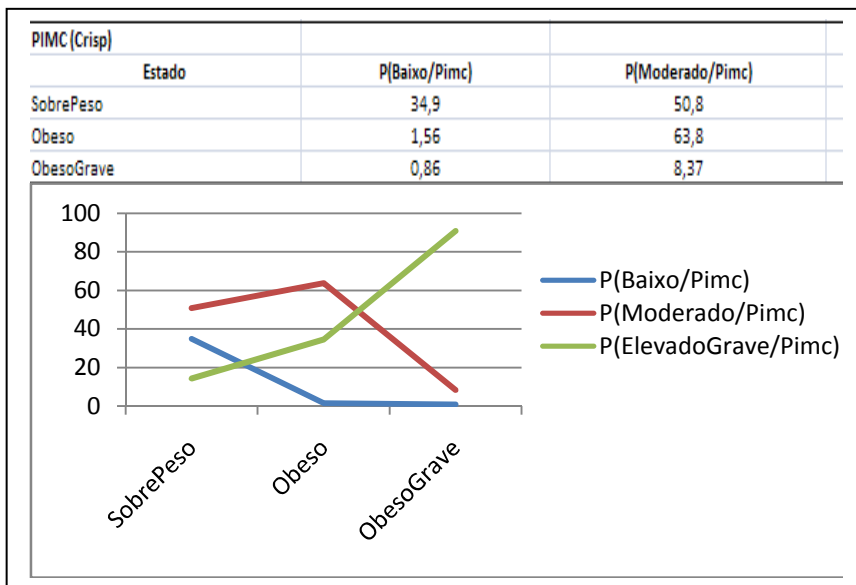


Figura 48 – Distribuição de Probabilidades para PIMC em estados Superpostos – inferência clássica
Fonte: (do autor)

Nota-se novamente o efeito gradual nas curvas de tendência que representam as distribuições das probabilidades obtidas pela inferência fuzzy-bayesiana. Matematicamente, a inferência sobre a *superposição* de um número de estados $n > 2$ tem a mesma eficácia nos casos mais simplificados, ou seja, quando da intersecção entre dois estados difusos vizinhos.

A compactação ou alongamento das linhas de tendência associadas às distribuições de probabilidades fuzzy-bayesianas dependem naturalmente da caracterização acerca da magnitude da imprecisão envolvida na dinâmica das variáveis do domínio modelado.

Simulação 7:

Pretende-se mostrar as distribuições de probabilidades fuzzy-bayesianas obtidas a partir da inferência sobre a variável AFS (Atividade Física Semanal), modelada como um Número Fuzzy.

Na verdade, qualquer efeito nas linhas de tendência das distribuições de probabilidades fuzzy-bayesianas está associado diretamente ao formato e aos parâmetros que modelam as funções de pertinência das variáveis imprecisas do domínio modelado. Portanto, em conformidade com a Teoria da lógica Fuzzy, cabe ao modelador, juntamente com o especialista, definirem conjuntamente esta parametrização de modo a alcançarem resultados mais realistas possíveis.

Seguindo este princípio, conforme a conveniência do caso adota-se o uso de Conjuntos Fuzzy e/ou de Números Fuzzy para a modelagem da imprecisão. Num primeiro plano, o que precisamos na realidade é obter um $E x$ $\varepsilon j k$ como sendo o melhor fator de ajuste da imprecisão que o método de inferência Fuzzy-Bayesiano necessita.

As figuras, 49 e 50 mostram, respectivamente, as distribuições das probabilidades fuzzy-bayesianas sobre a variável AFS e as distribuições de probabilidades da forma clássica.




Figura 49 – Distribuição de Probabilidades fuzzy-bayesianas para AFS

Fonte: (do autor)




Figura 50 – Distribuição de Probabilidades para AFS na forma clássica

Fonte: (do autor)

Novamente, é perceptível o efeito de mudança abrupta das linhas de tendência da figura 50, contudo, padrões similares em termos de ascendência e descendência nas linhas relativas à figura 49. Neste caso, os próprios valores de probabilidades associados ao conhecimento da Rede Bayesiana Clássica caracterizam alternâncias muito significativas, observadas na figura 49. O método Fuzzy-Bayesiano parece minimizar este efeito.

3.3.5 Verificação do Modelo mediante a análise do Especialista

Considerada as verificações a partir de simulações realizadas com dados de planilha (*análise absolutamente numérica com intervalos e valores condizentes a extratos de prontuário*) é oportuno verificar também a acurácia do modelo e o quão seus resultados refletem uma realidade observada pelo especialista médico que poderá utilizar tal artefato tecnológico justamente para que este lhe ofereça suporte em raciocínio complexo.

Por tratar-se de uma tese que enfatiza o papel do especialista em seu aspecto mais cognitivo diante de tarefa intensiva em conhecimento, algumas simulações que seguem ilustram esta comparação, observando a

forma (conjunto de regras) utilizada no processo de raciocínio clínico e diagnóstico.

A forma operacional das próximas simulações pretende verificar resultados de modo a identificar equivalências ou similaridades, ou ainda, possíveis discrepâncias entre aqueles obtidos, pelo método bayesiano clássico, pelo método Fuzzy-Bayesiano desenvolvido e pelo raciocínio clínico realizado por especialista numa perspectiva conforme mostra a figura 51:

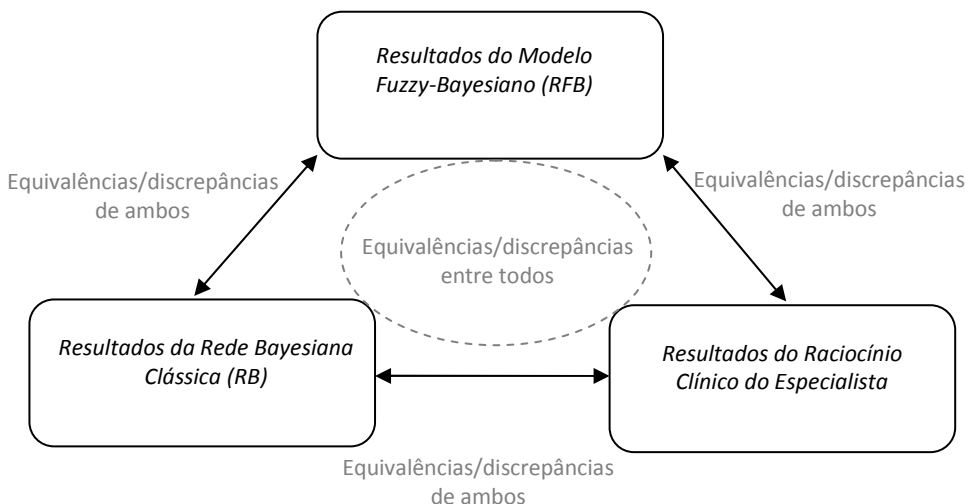


Figura 51 – Perspectiva da comparação de resultados da RB, RFB e do raciocínio clínico

Fonte: (do autor)

Foram utilizados dois conjuntos de dados trabalhados pelos especialistas em sua análise e raciocínio clínico que são apresentados pelas planilhas dos Anexos B e C. As simulações foram elaboradas conforme ilustra, com extratos parciais, o Apêndice I.

As tabelas, 6, 7 e 8 são organizadas de modo a apresentar, respectivamente:

- a) As probabilidades (classificação) obtidas pela Rede Bayesiana Clássica já referida na unidade (3.4.2) pela figura 35, a partir da confirmação das evidências sobre variáveis do tipo *Crisp* em conformidade com os casos apresentados no Anexo B;

- b) As probabilidades (classificação) obtidas pela aplicação da forma de inferência realizada pelo modelo Fuzzy-Bayesiano desenvolvido nesta tese. Nesta, levando-se em consideração a confirmação das mesmas variáveis do tipo *Crisp*, na forma do item (a) juntamente com as variáveis difusas e seus respectivos valores registrados no Anexo B, as quais são o motivo maior desta verificação de resultados, ou seja, observar as características do raciocínio Fuzzy-Bayesiano diante da complexidade do conhecimento e da dinâmica associada à *superposição* de estados (conceitos do domínio);
- c) A classificação, na forma descritiva, obtida pelo raciocínio clínico do especialista.

Para fins de verificação da dinâmica dos resultados obtidos pelo processo de inferência Fuzzy-Bayesiano aqui desenvolvido serão utilizados os valores de *score-z* como entradas para a variável difusa *PIMC* e também os valores de *CA* (medida de circunferência abdominal) para a variável difusa *PCA*.

A razão pela escolha destas duas variáveis, como entradas difusas ao modelo, é devido ao fato de se observar maior incidência do fenômeno da *Superposição de Estados*.

As demais variáveis que compõe a estrutura da Rede Bayesiana serão utilizadas como entradas do tipo *Crisp*. Com esta forma mista de entrada ao modelo Fuzzy-Bayesiano, utilizando-se de variáveis *Crisp* e também de variáveis *fuzzy* pretende-se demonstrar a eficácia e acurácia do modelo como sendo uma extensão às Redes Bayesianas Híbridas.

Tabela 6 – Classificações: Rede Bayesiana Clássica – 1º. Conjunto de Dados

Caso	Agregados <i>Fuzzy</i> (parte imprecisa)				Agregados <i>Crisp</i>			Rede Bayesiana Clássica		
	Score- z	CA	PIMC	PCA	PPA	AFS	Here	P(Risco=Baixo e)	P(Risco=Moderado e)	P(Risco=ElevadoGrave e)
1	2,34	84	Obeso	Alterada	N	S	0	0,086%	37%	62,9%
2	-0,04	54,4	Normal	Adequada	N	I	0	76,4%	23,5%	0,089%
3	1,62	60,7	SobrePeso	Adequada	N	A	2	99,6%	0%	0,37%
4	5,33	129	ObesoGrave	Alterada	A	I	1	0%	21,7%	78,3%
5	2,3	58	Obeso	Adequada	N	A	0	99,9%	0%	0,064%
6	0,95	70,5	Normal	Adequada	N	S	2	27,1%	33,9%	39%
7	3,58	91	ObesoGrave	Alterada	N	I	0	0,052%	54,5%	45,4%
8	1,98	76,2	SobrePeso	Alterada	N	A	2	38,1%	0%	61,9%
9	1,24	70,5	SobrePeso	Alterada	N	A	1	77,5%	0%	22,5%
10	1,76	74	SobrePeso	Alterada	N	S	0	3,35%	51,4%	45,3%
11	-2,57	69	Magreza	Adequada	N	I	0	78,6%	21,2%	0,19%
12	-2,73	63,7	Magreza	Adequada	A	I	0	0%	97,7%	2,31%

Fonte: (do autor)

Legenda:

CA = Circunferência Abdominal

PCA = Perfil de Circunferência Abdominal

AFS = Atividade Física Semanal

PIMC = Perfil de Índice de Massa Corpórea

PPA = Pressão Arterial

Here = Hereditariedade

e = a conjunção de todas as evidências observadas (entradas)

Tabela 7 – Classificações: Modelo Fuzzy-Bayesiano - 1º. Conjunto de Dados

Caso	Agregados <i>Fuzzy</i> (parte imprecisa)				Agregados <i>Crisp</i>			Modelo Fuzzy-Bayesiano		
	Score- z	CA	PIMC	PCA	PPA	AFS	Here	P(Risco=Baixo e)	P(Risco=Moderado e)	P(Risco=ElevadoGrave e)
1	2,34	84	Obeso	Alterada	N	S	0	0,53%	22,19%	76,10%
2	-0,04	54,4	Normal	Adequada	N	I	0	70,37%	29,45%	0,18%
3	1,62	60,7	SobrePeso	Adequada	N	A	2	82,89%	0%	17,11%
4	5,33	129	ObesoGrave	Alterada	A	I	1	0%	48,38%	51,62%
5	2,3	58	Obeso	Adequada	N	A	0	99,95%	0%	0,05%
6	0,95	70,5	Normal	Adequada	N	S	2	0,02%	8,94%	91,05%
7	3,58	91	ObesoGrave	Alterada	N	I	0	0,07%	82,96%	16,97%
8	1,98	76,2	SobrePeso	Alterada	N	A	2	8,52%	0%	91,48%
9	1,24	70,5	SobrePeso	Alterada	N	A	1	62,35%	0%	37,65%
10	1,76	74	SobrePeso	Alterada	N	S	0	1,05%	30,48%	68,47%
11	-2,57	69	Magreza	Adequada	N	I	0	4,41%	93,09%	2,51%
12	-2,73	63,7	Magreza	Adequada	A	I	0	0%	93,24%	6,76%

Fonte: (do autor)

Tabela 8 – Classificações: Raciocínio Clínico - 1º. Conjunto de Dados

Caso	Agregados <i>Fuzzy</i> (parte imprecisa)				Agregados <i>Crisp</i>			Raciocínio Clínico sobre Risco Metabólico (Forma descritiva)
	Score-z	CA	PIMC	PCA	PPA	AFS	Here	
1	2,34	84	Obeso	Alterada	N	S	0	Elevado Grave
2	-0,04	54,4	Normal	Adequada	N	I	0	Baixo
3	1,62	60,7	SobrePeso	Adequada	N	A	2	Moderado a Elevado
4	5,33	129	ObesoGrave	Alterada	A	I	1	Grave
5	2,3	58	Obeso	Adequada	N	A	0	Grave
6	0,95	70,5	Normal	Adequada	N	S	2	Moderado
7	3,58	91	ObesoGrave	Alterada	N	I	0	Grave
8	1,98	76,2	SobrePeso	Alterada	N	A	2	Moderado a Elevado
9	1,24	70,5	SobrePeso	Alterada	N	A	1	Moderado a Elevado
10	1,76	74	SobrePeso	Alterada	N	S	0	Elevado
11	-2,57	69	Magreza	Adequada	N	I	0	Moderado
12	-2,73	63,7	Magreza	Adequada	A	I	0	Moderado

Fonte: (do autor)

Para melhor possibilitar a discussão sobre os resultados apresentados pelas tabelas 6, 7 e 8 é propenso analisar os gráficos ilustrados pelas figuras 52, 53 e 54, de modo a observar as equivalências e as discrepâncias entre as classificações obtidas, respectivamente pelas três formas de inferência refletidas nas tabelas anteriores.

Importante salientar que, como o diagnóstico obtido pelo raciocínio clínico do especialista é de caráter descritivo, então optou-se em apresentar, por meio do gráfico de barras verticais, conforme mostra a figura 54, somente a classificação referente a tal diagnóstico, ocultando as demais, dado o fato que a classificação neste caso não releva valores de probabilidade, embora implícitos na crença do especialista.

Este fato do raciocínio clínico gerar uma classificação mais descritiva denota a relevância do emprego da Lógica Fuzzy, como parte que compõe o modelo Fuzzy-Bayesiano desta tese, para modelar o conhecimento baseado na representação lingüística e sua flexibilidade para explicar o fenômeno da imprecisão e da superposição conceitual, já discutida em unidades anteriores.

Notoriamente, alguns valores de probabilidades são pequenos o bastante para não projetarem sua representação. Sobre este aspecto é oportuno registrar o fato de que o software *Netica Norsys*, utilizado para construir a Rede Bayesiana Clássica, em algumas vezes gera resultados oriundos de problemas de arredondamento ou truncamento numérico, apresentando alguma dificuldade em torno da precisão de valores centesimais.




Figura 52 – Gráfico das classificações obtidas pela Rede Bayesiana Clássica sobre o primeiro conjunto de dados
 Fonte: (do autor)




Figura 53 – Gráfico das classificações obtidas pelo Modelo Fuzzy-Bayesiano sobre o primeiro conjunto de dados
Fonte: (do autor)




Figura 54 – Gráfico das classificações obtidas pelo Raciocínio Clínico sobre o primeiro conjunto de dados
 Fonte: (do autor)

Na sequência serão analisadas as características dos casos utilizados pela planilha do Anexo B que apresentam equivalências totais, parciais e as discrepâncias observadas no comparativo entre as três formas de inferência utilizadas nas simulações, obviamente, enfatizando aspectos mais notórios do modelo Fuzzy-Bayesiano.

Os casos 1, 2, 10 e 12 apresentam equivalências dos resultados das classificações obtidas pela Rede Bayesiana Clássica, pelo modelo Fuzzy-Bayesiano e pelo raciocínio clínico do especialista. Embora neste contexto, o modelo Fuzzy-Bayesiano acentua a classificação do caso 1 para o estado Risco = ElevadoGrave, convergindo para o mesmo resultado do raciocínio clínico e sendo melhor qualificado em relação a Rede Bayesiana Clássica. A mesma característica é observada no caso 2, acentuando a classificação para Risco = Baixo, também melhor convergindo com o raciocínio clínico. No caso 10, o modelo Fuzzy-Bayesiano também parece superar a qualidade do resultado se comparado com o raciocínio clínico, que classifica como Risco = Elevado e, neste caso, a Rede Bayesiana Clássica apontou probabilidade um pouco maior para Risco = Moderado. No caso 12, as três formas de inferência apontaram para a mesma classe Risco = Moderado.

No caso 4 o modelo Fuzzy-Bayesiano apresentou uma classificação parcialmente convergente com o resultado do raciocínio clínico e neste caso, a Rede Bayesiana Clássica teve melhor aproximação. Isso pode ser justificado pelo fato da estrutura da Rede Bayesiana especificar somente três estados na variável de saída – Risco-Metabólico. Ao observar a descrição dos critérios utilizados pelo raciocínio clínico (Anexo B), percebe-se a necessidade de envolver um novo estado intermediário entre Moderado e ElevadoGrave na especificação da variável de saída da Rede Bayesiana Clássica, que poderia ser, conforme consta no Anexo B, um estado denominado – Elevado, o qual seria um estado de transição entre Moderado e ElevadoGrave. O modelo Fuzzy-Bayesiano terminou por compensar esta necessidade de melhor classificar diante da imprecisão atribuindo uma probabilidade maior para Risco = Moderado.

No caso 6 o modelo Fuzzy-Bayesiano acentuou a probabilidade de Risco = ElevadoGrave, afastando-se do resultado do raciocínio clínico e estabelecendo certa tendência aos resultados do modelo clássico de raciocínio bayesiano. Contudo, ao observar a descrição dos critérios utilizados no raciocínio clínico vê-se que o valor da variável CA está próximo do ponto de corte e que a colocaria no estado de Alterada. Como o modelo Fuzzy-Bayesiano releva significativamente este aspecto de transição em torno do fator imprecisão, isso contribui para certa disparidade entre os resultados da classificação.

No caso 7 a classificação obtida pelo modelo Fuzzy-Bayesiano também acentuou a probabilidade para Risco = Moderado, diminuindo a probabilidade de Risco = Grave conforme apontou o resultado do raciocínio clínico. Novamente, percebe-se a necessidade de melhor estruturar a Rede Bayesiana especificando novos estados intermediários na variável de saída para permitir maior flexibilidade no raciocínio.

No caso 11 o modelo Fuzzy-Bayesiano apresenta equivalência ao raciocínio clínico e acentua ainda mais a probabilidade de Risco = Moderado. Neste caso, a Rede Bayesiana Clássica divergiu totalmente por apontar maior probabilidade para Risco = Baixo.

Nos demais casos 3, 5 e 9 os resultados obtidos pelo modelo Fuzzy-Bayesiano e pela Rede Bayesiana Clássica apresentam similaridades no aspecto de tendências das probabilidades, mas, ambos diferenciam-se significativamente dos resultados do raciocínio clínico. Assim como no caso 8 existem certas discrepâncias entre os resultados dos dois modelos estocásticos e dos resultados clínicos, com tendências mais acentuadas para Risco = Baixo e Risco = Elevado Grave.

Uma razão para estas divergências entre os modelos artificiais em relação ao processo de raciocínio clínico estaria localizada no fato da estrutura da Rede Bayesiana possuir prováveis equívocos em sua especificação qualitativa e também quantitativa. Seria propenso avaliar se as relações causais da Rede Bayesiana utilizada nestas simulações estariam de fato representando o conhecimento sobre o domínio, em especial, observando as especificações sobre variáveis e estados que denotam a necessidade de maior refinamento para representar o conhecimento sobre imprecisão e superposição conceitual.

Na sequência são apresentadas as tabelas 9, 10 e 11 referentes aos resultados das classificações aplicadas sobre o segundo conjuntos de dados registrados pela planilha do Anexo C.

Do mesmo modo que o conjunto anterior realizou-se o comparativo dos resultados obtidos pela Rede Bayesiana Clássica, pelo modelo Fuzzy-Bayesiano desenvolvido nesta tese e os resultados do raciocínio clínico.

Os gráficos das figuras 55 e 56 mostram os resultados da Rede Bayesiana Clássica e do modelo Fuzzy-Bayesiano e o gráfico da figura 57 mostra somente o estado da variável de saída com classificação total, ou seja, o resultado descritivo do diagnóstico clínico mapeado para uma forma numérica de probabilidade = 100%.

Este critério de comparação dos gráficos, também foi utilizado para o conjunto de dados anterior, embora, é importante salientar que, implicitamente, o raciocínio clínico parece ser mais do tipo lingüístico,

numa forma similar ao raciocínio heurístico permitido pelos modelos de imprecisão representados por conjuntos fuzzy.

Mediante um cenário de regras que estabelece pontos de corte abruptos, o especialista parece encontrar alguma dificuldade na classificação dada à dinâmica da superposição de estados.

Tabela 9 – Classificações: Rede Bayesiana Clássica - 2º. Conjunto de Dados

Caso	Agregados <i>Fuzzy</i> (parte imprecisa)				Agregados <i>Crisp</i>			Rede Bayesiana Clássica		
	Score- z	CA	PIMC	PCA	PPA	AFS	Here	P(Risco=Baixo e)	P(Risco=Moderado e)	P(Risco=ElevadoGrave e)
1	0,59	77	Normal	Adequada	N	A	0	100%	0%	0%
2	3,19	104	ObesoGrave	Alterada	N	I	2	0%	13,9%	86,1%
3	0,88	71	Normal	Alterada	N	A	0	99,9%	0%	0,08%
4	2,2	85	Obeso	Alterada	N	A	0	78,1%	0%	21,9%
5	2,92	79	Obeso	Alterada	N	A	2	1,13%	0%	98,9%
6	3,24	95	ObesoGrave	Alterada	A	A	1	0%	0%	100%
7	1,52	76,5	SobrePeso	Alterada	N	A	0	99,5%	0%	0,52%
8	2,75	110	Obeso	Alterada	A	I	1	0%	84,7%	13,5%
9	1	59,2	SobrePeso	Adequada	N	A	0	100%	0%	0%

Fonte: (do autor)

Tabela 10 – Classificações: Modelo Fuzzy-Bayesiano - 2°. Conjunto de Dados

Caso	Agregados <i>Fuzzy</i> (parte imprecisa)				Agregados <i>Crisp</i>			Modelo Fuzzy-Bayesiano		
	Score- z	CA	PIMC	PCA	PPA	AFS	Here	P(Risco=Baixo e)	P(Risco=Moderado e)	P(Risco=ElevadoGrave e)
1	0,59	77	Normal	Adequada	N	A	0	99,56%	0%	0,44%
2	3,19	104	ObesoGrave	Alterada	N	I	2	0%	49,49%	50,51%
3	0,88	71	Normal	Alterada	N	A	0	99,32%	0%	0,68%
4	2,2	85	Obeso	Alterada	N	A	0	95,57%	0%	4,43%
5	2,92	79	Obeso	Alterada	N	A	2	2,6%	0%	97,4%
6	3,24	95	ObesoGrave	Alterada	A	A	1	0%	0%	100%
7	1,52	76,5	SobrePeso	Alterada	N	A	0	98,14%	0%	1,86%
8	2,75	110	Obeso	Alterada	A	I	1	0%	69,69%	30,31%
9	1	59,2	SobrePeso	Adequada	N	A	0	99,98%	0%	0,02%

Fonte: (do autor)

Tabela 11 – Classificações: Raciocínio Clínico - 2º. Conjunto de Dados

Caso	Agregados <i>Fuzzy</i> (parte imprecisa)				Agregados <i>Crisp</i>			Raciocínio Clínico sobre Risco Metabólico (Forma descritiva)
	Score- z	CA	PIMC	PCA	PPA	AFS	Here	
1	0,59	77	Normal	Adequada	N	A	0	Baixo
2	3,19	104	ObesoGrave	Alterada	N	I	2	Grave
3	0,88	71	Normal	Alterada	N	A	0	Baixo a Moderado
4	2,2	85	Obeso	Alterada	N	A	0	Elevado a Grave
5	2,92	79	Obeso	Alterada	N	A	2	Elevado a Grave
6	3,24	95	ObesoGrave	Alterada	A	A	1	Grave
7	1,52	76,5	SobrePeso	Alterada	N	A	0	Moderado a Elevado
8	2,75	110	Obeso	Alterada	A	I	1	Elevado a Grave
9	1	59,2	SobrePeso	Adequada	N	A	0	Moderado a Elevado

Fonte: (do autor)




Figura 55 – Gráfico das classificações obtidas pela Rede Bayesiana Clássica sobre o segundo conjunto de dados
 Fonte: (do autor)




Figura 56 – Gráfico das classificações obtidas pelo Modelo Fuzzy-Bayesiano sobre o segundo conjunto de dados
Fonte: (do autor)




Figura 57 – Gráfico das classificações obtidas pelo Raciocínio Clínico sobre o segundo conjunto de dados
Fonte: (do autor)

As características notadas sobre os resultados da classificação de Risco Metabólico obtidas nas simulações sobre o segundo conjunto de dados disposto na planilha, Anexo C, mostraram as mesmas tendências observadas no conjunto anterior, em termos das equivalências, similaridades parciais e discrepâncias.

Apresentaram equivalências entre os resultados da Rede Bayesiana Clássica, do modelo Fuzzy-Bayesiano e do raciocínio clínico os casos, 1, 2, 5 e 6.

No caso 8, o modelo Fuzzy-Bayesiano classificou com tendências mais similares (transição gradual pouco acentuada entre os estados) em relação ao raciocínio clínico.

Nos casos 3, 4, 7 e 9 o modelo bayesiano clássico e o modelo Fuzzy-Bayesiano apresentaram tendências similares, embora, diferentes dos resultados do raciocínio clínico. Sobre este aspecto, é perceptível novamente, observando a análise descritiva do especialista conforme retratado no Anexo C, que pode haver a necessidade de reestruturação das relações causais da Rede Bayesiana que representa o conhecimento do domínio ou ainda o refinamento da especificação dos estados da variável de saída.

4 CONSIDERAÇÕES FINAIS

Esta pesquisa apresentou resultados que sugerem conclusões convergentes às expectativas associadas aos pressupostos elencados pelos objetivos específicos, bem como às respostas alcançadas à pergunta de pesquisa estabelecida a priori. Durante o desenvolvimento da modelagem proposta pela tese foram observadas, vantagens e também, limitações impostas pelo cenário de aplicação do modelo. Em resposta ao objetivo maior desta tese vislumbraram-se possíveis novas propostas de investigação para a continuidade das pesquisas no campo da Engenharia do Conhecimento as quais serão apresentadas como temas para futuros trabalhos de pesquisa.

Num primeiro momento, observou-se com clareza que a problemática do conhecimento sobre incertezas, elucidada pelo domínio tratado por esta pesquisa, demandou a busca por uma forma híbrida de solução a partir de um artefato tecnológico propiciado pelo emprego de uma visão sistêmica e sustentado por abordagem transdisciplinar.

O fator incerteza não pode ser analisado e solucionado simplesmente com a aplicação de técnicas numa forma de utilização *ad hoc*, mas, deve-se compreender todo o contexto que circunda o cenário pelo qual o problema aponta a incerteza como maior desafio. Esta percepção resultou no desenvolvimento de um modelo de inferência aliado às características de atuação do especialista clínico no que refere-se ao raciocínio aplicado sobre variáveis em cenário complexo.

No âmbito da diagnose clínica o uso de Sistemas Especialistas, de uma maneira absoluta, pode estar desprovido de uma visão mais completa e detalhada de todos os aspectos ligados ao fator incerteza presente na atividade do especialista. As Redes Bayesianas Clássicas são soluções triviais em problemas de classificação envolvendo o fator aleatoriedade. Contudo, possuem limitações quando para esta classificação as probabilidades não são as únicas formas de representação de incerteza.

No exercício da Classificação de Risco Metabólico em crianças e adolescentes, o especialista emprega intensivamente seu conhecimento e em seu aspecto mais cognitivo depara-se não somente com o problema das variáveis aleatórias, mas também, com o fator imprecisão imerso nas definições conceituais e nas relações entre as variáveis do domínio.

As Redes Bayesianas Clássicas mostraram-se não apropriadas para classificações em que as variáveis probabilísticas estão associadas à imprecisão e, como ferramenta de suporte ao raciocínio do especialista

humano, pode induzir a conclusões equivocadas em termos de uma tomada de decisão frente à aferição realizada em pacientes.

A imprecisão não foi a única característica mais observada como fator de incerteza no cenário da problemática, mas, uma aproximação acentuada entre os termos lingüísticos que definiram os estados das variáveis especificadas. Esta aproximação sugeriu a adoção de uma forma de Superposição Conceitual na especificação dos estados das variáveis, considerada na conjectura matemática do modelo e que mostrou-se uma forma eficaz de representar a dinâmica do raciocínio sobre conhecimento complexo.

Diante deste novo aspecto em que ocorre esta Superposição Conceitual, o Princípio da Superposição de Estados, da Física Quântica mostrou-se como uma apropriada argumentação científica. Esta observação vem a calhar com as considerações epistemológicas desta pesquisa quando discorre sobre a visão complexa da atuação do Engenheiro do Conhecimento. Por meio da “*interpretação da complementaridade*” e da “*visão instrumentalista*”, os quais são alguns alicerces teóricos deste princípio da Física Quântica, considerou-se que tal princípio poderia ser instanciado ao problema desta pesquisa como uma inspiração. Para elucidar esta conclusão, reportamo-nos aos resultados das simulações, cujos valores aferidos sobre as variáveis PIMC, PCA e AFS quase sempre denotaram superposição, principalmente, na confirmação da evidência *PIMC*, com superposição dos estados - *SobrePeso*, *Obeso* e *ObesoGrave*.

O modelo de inferência Fuzzy-Bayesiano com estados não-dicotômicos raciocinou diante desta superposição e classificou a variável de saída (H_i) acompanhando a dinâmica inerente.

O emprego da Lógica Fuzzy na especificação do modelo não-dicotômico de raciocínio Fuzzy-Bayesiano apresentou a mesma eficácia já observada no modelo dicotômico revisado, acentuando a capacidade de representar o conhecimento por meio de variáveis com múltiplos estados. O modelo apresenta flexibilidade em relação à parametrização ou configuração das funções de pertinência fuzzy utilizadas para ajustar o conhecimento da Rede em virtude da imprecisão inerente. Esta característica é fundamental para o processo de redefinição do conhecimento representado pela Rede Fuzzy-Bayesiana por parte do especialista de modo a otimizar a qualidade desta representatividade, melhorando os resultados para futuros diagnósticos.

Durante a etapa de desenvolvimento da modelagem foram propostas algumas indagações em relação aos resultados esperados pelo processo de inferência Fuzzy-Bayesiano não-dicotômico. Observou-se que o fator imprecisão modificou as curvas de tendência das distribuições de

probabilidade da classificação sobre a variável de saída – “RiscoMetabólico”. No entanto, não ocorreu o efeito de “*espalhamento*”, conforme já havia sido notado no modelo dicotômico revisado na literatura. Também, nada se pôde afirmar sobre a existência de alguma relação entre a *entropia* da rede com o efeito de distribuição das probabilidades fuzzy-bayesianas para o modelo não-dicotômico.

O efeito ou comportamento marcante nas curvas de tendência das distribuições de probabilidades após a propagação dada pela inferência fuzzy-bayesiana desenvolvida é que estas novas distribuições parecem acompanhar a dinâmica inerente à própria imprecisão associada às evidências e seus estados difusos e superpostos. O comportamento alonga e compacta os mínimos e máximos das curvas conforme a transição gradual que acontece pela aferição da medida de possibilidade dos estados.

Outro aspecto notório do formalismo empregado na construção do modelo de inferência e de sua aplicação sobre a estrutura da base de conhecimento utilizada nas simulações foi a manutenção da propriedade $\sum P(H_i) = 1$ para a variável de saída – “RiscoMetabólico”. No entanto, este axioma da Teoria da Probabilidade não mais se aplica sobre as variáveis de entrada, ou seja, as evidências apresentadas a Rede, agora, Fuzzy-Bayesiana. A inserção de qualificadores difusos na formulação matemática do modelo de inferência desenvolvido mudou a conotação destas variáveis E_j após a distribuição das probabilidades conjuntas, fazendo com que seu aspecto mude de probabilístico para possibilístico, embora, na base de conhecimento, as *CPTs* preservam as probabilidades originais. Nota-se então que E_j , após a propagação, passa a ser um *agregado* de conceitos que confirmam uma medida de possibilidade para múltiplos estados superpostos. Um argumento conclusivo acerca deste efeito é que E_j , quando associado à imprecisão deixa de ser simplesmente um evento ou evidência observada num espectro de probabilidades (*chance de ocorrência*), mas, uma possibilidade aferida. Esta observação pode ser vista como um diferencial em relação aos modelos dicotômicos identificados na revisão da literatura, os quais se propõem a conservar o axioma da “somatória igual a 1” sobre as evidências após a propagação conjunta por meio de uma operação complementar na forma $P(e_1) = 1 - P(e_2)$.

Uma pergunta de pesquisa estabelecida no início desta investigação também discorreu de modo sugestivo sobre a possibilidade da realização de estudos mais específicos em relação à elaboração de ontologias estocásticas com constructos necessários para a obtenção de suporte do processo de raciocínio Fuzzy-Bayesiano desenvolvido no modelo desta pesquisa. Desta forma, após a revisão da literatura e do desenvolvimento do modelo proposto, conclui-se que tais conjecturas do ponto de vista da Engenharia

de Ontologias podem ser desenvolvidas, haja vista que objetivos similares foram alcançados nas propostas das linguagens *PR-OWL*, *ontoBayes* e *Fuzzy Ontology*, já citadas no trabalho.

O modelo Fuzzy-Bayesiano teve sua acurácia verificada por simulação numérica a partir de dados gerais registrados em planilhas de prontuários. Esta verificação permitiu concluir que, matematicamente, o modelo converge com as expectativas num espectro de tratamento de conhecimento de natureza estocástica. Por outro lado, o modelo também foi verificado diante de resultados obtidos por raciocínio clínico e mostrou-se significativamente correlato a forma de inferência do especialista. As tabelas, 12 e 13 resumem a análise comparativa dos resultados obtidos na discussão da unidade (3.3.5) e mostra que o primeiro conjunto de dados trouxe um cenário mais adequado às conclusões sobre a eficiência do modelo desenvolvido frente ao modelo clássico e ao parecer descritivo obtido pelo raciocínio clínico.

As discrepâncias e até as similaridades parciais entre os resultados obtidos pelo modelo Fuzzy-Bayesiano e pelo raciocínio clínico mostraram a necessidade de revisão das relações de causalidade da parte estrutural da Rede Bayesiana que representa o conhecimento do especialista. Além deste aspecto, estas diferenças podem ser justificadas pelo fato do Modelo Fuzzy-Bayesiano possuir a flexibilidade de raciocinar sobre imprecisão e superposição atribuindo valores ajustados de probabilidades aos estados da variável de saída de modo a acompanhar a dinâmica relacionada com a imprecisão aferida. O modelo clássico não raciocina desta forma e termina por compensar abruptamente um estado com uma probabilidade de valor, às vezes, exageradamente alto.

A Superposição Conceitual mostrou-se um recurso apropriado para minimizar este efeito de classificação equivocada nos intervalos próximos aos pontos de corte, mais do que a utilização de Conjuntos Fuzzy somente com intersecção de dois estados vizinhos complementares. Superposição de vários Conjuntos Fuzzy por meio de suas funções de pertinência representam ainda melhor a dinâmica que favorece a distribuição das probabilidades de saída diante da transição gradual entre seus estados.

As curvas de tendência nas distribuições das probabilidades propagadas pela inferência fuzzy-bayesiana mostraram-se condizentes, na maioria dos dados simulados, com a forma de raciocínio aproximado utilizado pelo especialista clínico.

Almeja-se que especialistas médicos possam utilizar o modelo para apoiar seus processos de diagnose e mostrar o cenário em que emerge o Risco Metabólico frente às reais situações observadas em seus pacientes e

com isso, tomar decisões mais eficientes do que aquelas que seriam tomadas sem o provimento do suporte a predição.

Conclui-se que o modelo fuzzy-bayesiano desenvolvido nesta pesquisa propõe o início de uma perspectiva voltada a investigação de abordagens híbridas para lidar com o fenômeno da incerteza no âmbito da representação do conhecimento.

Tabela 12 – Resumo da discussão de resultados – 1º. Conjunto de dados

Conjunto	Equivalências					
	RB x Clínico		RFB x Clínico		RFB x RB	
	<i>n</i>	%	<i>n</i>	%	<i>n</i>	%
1	5	41,6	7	58,3	10	83,3
(12 casos)	Casos: 1, 2, 4, 8 e 12		Casos: 1, 2, 4, 8, 10, 11 e 12		Casos: 1, 2, 3, 4, 5, 6, 7, 8, 9 e 12	
Observações: Equivalências e Discordâncias	<p>Caso=1, melhor resultado da RFB em relação ao parecer descritivo do raciocínio clínico.</p> <p>Caso=2, RFB elevou um pouco a probabilidade para Moderado. Assim, aproxima do parecer clínico quando sugere ao paciente aumentar a atividade física semanal.</p> <p>Caso=3, os dois modelos discordam do parecer clínico.</p> <p>Caso=4, RFB minimiza a classificação de risco=grave para risco=moderado. Justificada pela imprecisão aferida nas evidências apresentadas.</p> <p>Caso=5, os dois modelos discordam do parecer clínico.</p> <p>Caso=6, os dois modelos discordam do parecer clínico.</p> <p>Caso=7, os dois modelos discordam do parecer clínico.</p> <p>Caso=8, RFB apresenta melhor aproximação ao parecer clínico.</p> <p>Caso=9, os dois modelos discordam do parecer clínico.</p> <p>Caso=10, RFB concorda com o parecer clínico minimizando a margem de risco=grave devido a imprecisão das evidências. Neste caso, o modelo clássico difere totalmente.</p> <p>Caso=11, RFB concorda com o parecer clínico, acentuando a margem de classificação de risco=moderado. O modelo clássico difere totalmente.</p> <p>Caso=12, concordância mútua entre as três formas de raciocínio.</p>					

Fonte: (do autor)

Tabela 13 – Resumo da discussão de resultados – 2°. Conjunto de dados

Conjunto	Equivalências					
	RB x Clínico		RFB x Clínico		RFB x RB	
	<i>n</i>	%	<i>n</i>	%	<i>n</i>	%
2	4	44,4	4	44,4	9	100
(9 casos)	Casos: 1, 2, 5 e 6		Casos: 1, 2, 5 e 6		Casos: 1, 2, 3, 4, 5, 6, 7, 8 e 9	
Observações: Equivalências e Discordâncias	<p>Caso=1, concordância mútua entre as três formas de raciocínio.</p> <p>Caso=2, RFB concorda com o parecer clínico minimizando a margem de risco=grave devido a imprecisão das evidências.</p> <p>Caso=3, os dois modelos discordam do parecer clínico.</p> <p>Caso=4, os dois modelos discordam do parecer clínico.</p> <p>Caso=5, concordância mútua entre as três formas de raciocínio.</p> <p>Caso=6, concordância mútua entre as três formas de raciocínio.</p> <p>Caso=7, os dois modelos discordam do parecer clínico.</p> <p>Caso=8, os dois modelos discordam do parecer clínico, embora, a RFB melhor se aproxima da classificação gradual de risco=moderado para grave, acompanhando a imprecisão das evidências.</p> <p>Caso=9, os dois modelos discordam do parecer clínico.</p>					

Fonte: (do autor)

5 SUGESTÕES PARA FUTUROS TRABALHOS

Considerados os aspectos conclusivos, vantagens, limitações e oportunidades encontradas durante esta pesquisa, em continuidade ao processo de aprimoramento da Engenharia do Conhecimento sugerem-se:

- Elaborar software de simulação com interface apropriada para representar, inferir e realizar consultas de modo a fornecer suporte à atividade de diagnóstico clínico;
- Desenvolver um *framework* orientado a construção de Redes Fuzzy-Bayesianas com motor de inferência (raciocinador) especificado conforme o modelo desenvolvido nesta tese, de modo a atender às demandas não atendidas por ferramentas tais como *Netica Norsys* e outras destinadas ao tratamento estocástico da informação e do conhecimento;
- Investigar a influência da parametrização dos valores de suporte dos conjuntos fuzzy que modelam a imprecisão na representação do conhecimento. Propor novas formas de funções de pertinência que asseguram maior flexibilidade para representar a transição entre estados superpostos;
- Propor a redefinição de parâmetros do modelo Fuzzy-Bayesiano de modo a aplicá-lo na representação e inferência sobre o conhecimento em outros domínios com acentuada dinâmica, por exemplo, no âmbito do estudo da Classificação de Solos e em previsões Meteorológicas;
- No âmbito da Engenharia de Ontologias, desenvolver aspectos estruturais e principalmente sintáticos que permitam a especificação de ontologias para representar este tipo de conhecimento estocástico vinculado a aleatoriedade e a imprecisão, e também, elaborar formas de mapeamento desta ontologia para uma Rede Fuzzy-Bayesiana que utilize o modelo de inferência desenvolvido nesta pesquisa. Averiguar então as vantagens quanto à representação de conhecimento compartilhado em domínios com incerteza;

- Investigar modos de acoplamento do modelo desenvolvido a *frameworks* voltados para a construção de Sistemas de Conhecimento, por exemplo, como acoplar esta solução ao Modelo de Conhecimento, segundo a proposta do *CommonKads*;
- Investigar possíveis relações entre o conceito de Processo Markoviano e o raciocínio do especialista quando este infere diante da imprecisão caracterizada nos Estados Superpostos das variáveis do domínio, referindo-se ao fator que poder-se-ia denominar no momento de “memória dos estados superpostos”.

REFERÊNCIAS BIBLIOGRÁFICAS

ABE, J. M. **Fundamentos da Lógica Anotada**. Tese de Doutorado, FFLCH/USP. São Paulo, 1992.

ABEL, M. **Estudo da pericia em petrografia sedimentar e sua importância para a Engenharia do Conhecimento**. Porto Alegre. Programa de pós-graduação em Ciência da Computação. Tese de Doutorado, 2001.

ANDRADE, M. T. C. **Computação Fuzzy**. Material Didático. Departamento de Engenharia de Computação e Sistemas Digitais – EPUSP. Acesso em: <novembro de 2012>.

ARAÚJO, P. C. **Uma Metodologia de Pesquisa em Educação Matemática: Estatística Bayesiana e Conjuntos Difusos**. Anais do Encontro de Produção Discente PUC/SP. São Paulo. P.1-12, 2012.

BALDWIN, Jim F. **A mass assignment theory for uncertainty reasoning**. 0-7803-0236-21 92. IEEE. 1367-1374. 1992.

BALDWIN, JIM F.; TOMASO, ENZA DI. **Inference and Learning in Fuzzy Bayesian Networks**. The IEEE International Conference on Fuzzy Systems. 2003

BALDWIN, JIM F.; TOMASO, ENZA DI. **An approach to hybrid probabilistic models**. International Journal of Approximate Reasoning 47. 202–218. 2008.

BARD, J.; RHEE, S. **Ontologies in biology: design applications and future challenges**. Nature Reviews Genetics, 5:213–222, 2004.

BARROS, L. C. **Sobre Sistemas Dinâmicos Fuzzy – Teoria e Aplicações**. Tese de Doutorado. UNICAMP. São Paulo, 1997.

BERNARDO C. DE O; VASCONCELOS F. DE A. **Association of parents' nutritional status, and sociodemographic and dietary factors with overweight/obesity in schoolchildren 7 to 14 years old**. Cad Saude Publica. Feb 2012;28(2):291-304.

BOBILLO, F.; STRACCIA, U. **Fuzzy ontology representation using OWL 2**. International Journal of Approximate Reasoning. Elsevier Published, 2011.

BOHR, N. **Física atômica e conhecimento humano: ensaios 1932-1957**. RJ. Contraponto Editora Ltda, 1995.

BORGELT, C.; KRUSE, R. Evaluation **measures for learning probabilistic and possibilistic networks**. IEEE. Fuzzy-IEEE'97. 669-676. 1997.

BORGES, M. A., BRIGNOLI, J. T., SILVA, E. R. G. DA, MORALES, A. B. T., SELL, D., FREIRE, P. DE SÁ. **Ontologias fuzzy: uma investigação preliminar com o recurso da revisão sistemática** In: Congresso Brasileiro de Sistemas Fuzzy, 2010, Sorocaba. Anais do Congresso Brasileiro de Sistemas Fuzzy. Sorocaba : UFScar, 2010. -: -, 2010. v.0. p.0 – 0

BORLAWSKY, T.; FRIEDMAN, C.; LUSSIER, Y. A. **Generating Executable Knowledge for Evidence-Based Medicine Using Natural Language and Semantic Processing**. AMIA Annu Symp Proc. 2006; 2006: 56–60.

BORST, W. N. **Construction of Engineering Ontologies**. 1997. Thesis (Ph. D.) University of Twente – Centre for Telematica and Information Technology, Enschede, Nederland, 1997.

BRIGNOLI, J. T. **Modelo híbrido difuso-probabilístico – uma alternativa para sistemas especialistas**. Dissertação de mestrado. Curso de Pós-graduação em Ciência da Computação. UFSC. Florianópolis, 2001.

BRIGNOLI, J. T.; SELL, DENILSON; GAUTHIER, F. O. **Abordagens Estocásticas para Raciocinadores Aplicáveis em web Semântica**. Ontobras MOST. Gramado-RS, 2011.

BUNGE, M. **Philosophy of the Social Sciences – Mechanism and Explanation**. Sage Publications, 1997.

BUNGE, M. **Seudo ciencia e ideología**. Madrid: Alianza, 1985.

CARVALHO, R. N. **Plausible reasoning in the semantic web using Multi-Entity bayesian networks – MEBN**. M.Sc., University of Brasília, Brasilia, Brazil, Feb. 2008.

CARVALHO, R. N. **Probabilistic Ontology: Representation and Modeling Methodology**. George Mason University, 2011.

CAVALCANTI, J. H. F.; MELO H. DE; SOUTO, C.; CAVALCANTI, M. **Lógica Fuzzy aplicada as Engenharias**. Câmara do Livro Brasil, 2012.

CHARNIAK, E. **Bayesian networks without tears: making bayesian networks more accessible to the probabilistically unsophisticated**. AI Mag., American Association for Artificial Intelligence, Menlo Park, CA, USA, 1991.

CHEN, YUAN YAN. **Fuzzy Analysis of Statistical Evidence**. IEEE transactions on fuzzy systems, vol. 8. Nro. 6. 2000.

COLETTI, G.; GERVASI, O.; TASSO, S.; VANTAGGI, B. **GENERALIZED BAYESIAN INFERENCE IN A FUZZY CONTEXT: FROM THEORY TO A VIRTUAL REALITY application**. Journal Computational Statistics & Data Analysis archive. vol. 56 Issue 4, p. 967-980. 2012.

COSTA, P. C. G. **Bayesian Semantics for the Semantic Web**. George Mason University, 2005.

COSTA, P. C. G. ; CARVALHO, R. N.; LASKEY, K. B.; Park, C. Y. **Evaluating uncertainty representation and reasoning in HLF systems**. 978-0-9824438-2-8/11. IEEE. 2011.

CUPANI, ALBERTO. **La peculiaridad Del conocimiento tecnológico**. Scientia Studia, São Paulo, v.4, n.3, p.353-71, 2006.

D'ANGELO, MARCOS F.S.V.; PALHARES, R. M.; TAKANASHI, R. H. C.; LOSCHI, R. H.; BACCARINI, L. M. R.; CAMINHAS, W. M. **Incipient fault detection in induction machine stator-winding using a fuzzy-Bayesian change point detection approach**. Applied Soft Computing. Vol. 11. 179–192. 2011.

DING, Z. **Bayes OWL: A Probabilistic framework for Uncertainty in Semantic Web**. University of Maryland Baltimore Country, 2005.

DING, Z.; PENG, Y. **A Probabilistic Extension to Ontology language OWL**. University of Maryland Baltimore Country, 2004.

EISBERG, R.; RESNICK, R. **Quantum Physics of Atoms, Molecules, Solids, Nuclei and Particles**. Second Edition. University of California, 1985.

FAN, CHIN-YUAN; CHANG, PEI-CHANN; LIN, JYUN-JIE; HSIEH, J.C. **A hybrid model combining case-based reasoning and fuzzy decision tree for medical data classification**. Applied Soft Computing 11. 632–644. Elsevier. 2011.

FEIGENBAUM, E.; BUCHANAN, B.; LEDERBERG, J. **On generality and problem solving: a case study using the dendral program**. In: MACHINE INTELLIGENCE, 1971, Edinburgh, GB. Anais. Edinburgh University Press, 1971. v.6, p.165.190.

FERREIRA, A. B. DE HOLLANDA. **Dicionário Aurélio Eletrônico**. 2013.

FERREIRA, L.; BORENSTEIN, D. **A fuzzy-Bayesian model for supplier selection**. Journal Expert Systems with Applications: An International Journal archive. vol. 39. Issue 9. p. 7834-7844. 2012.

FOGELBERG, C.; PALADE, V.; ASSHETON, P. **Belief Propagation in Fuzzy Bayesian Networks**. 1st International Workshop on Combinations of Intelligent Methods and Applications(CIMA) at ECAI'08. Ioannis Hatzilygeroudis, University of Patras, Greece, 2008.

FREDRIKS AM, VAN BUUREN S, FEKKES M, VERLOOVE-VANHORICK SP, WIT JM. **Are age references for waist circumference, hip circumference and waist-hip ratio in Dutch children useful in clinical practice?** Eur J Pediatr. Apr 2005;164(4):216-222.

FREEDMAN, DAVID S.; ZUGUO, MEI; SATHANUR, R. SRINIVASAN; GERALD S. BERENSON; WILLIAM H. DIETZ. **Cardiovascular Risk Factors and Excess Adiposity Among**

Overweight Children and Adolescents: The Bogalusa Heart Study. J Pediatr;150:12-7, 2007.

FREITAS, H. *et al.* **Informação e Decisão: sistemas de apoio e seu impacto.** Porto Alegre: Ortiz, 1997.

FRÜHWIRTH, S. **On Fuzzy Bayesian Inference.** Forschungsberichte/Institut für Statistik, 17. Department of Statistics and Mathematics, WU Vienna University of Economics and Business, Vienna, 1990.

FRÜHWIRTH, S. **On statistical inference for fuzzy data with applications to descriptive statistics.** Fuzzy Sets and Systems 50, 143-165. North-Holland, 1992.

GEENEN, ERWIN VAN. **Knowledge Structures and the usability of Knowledge Systems.** ISBN: 90-5972-044-X. Amsterdam, 2004.

GERTNER, G.Z.; ZHU, H. **Bayesian estimation in forest surveys when samples or prior information are fuzzy.** Fuzzy Sets and Systems 77. 277-290. Elsevier. 1996.

GIULIANO IDE C, COUTINHO MS, FREITAS SF, PIRES MM, ZUNINO JN, RIBEIRO RQ. **Serum lipids in school kids and adolescents from Florianopolis, SC, Brazil--Healthy Floripa 2040 study.** Arq Bras Cardiol. Aug 2005; 85(2):85-91.

GOLDMAN, R. **Probabilistic Approach to Language Understanding.** [S.l.], 1990.

GRUBER, TR. **Toward principles for the design of ontologies used for knowledge sharing.** IN: Guarino N, Poli R (eds) International Workshop on Formal Ontology in Conceptual Analysis and Knowledge Representation. Padova, Italy, 1993.

HART, P.; DUDA, R.; EINAUDI, M. **Prospector - a computer-based consultation system for mineral exploration.** In: MATHEMATICAL GEOLOGY, 1978. Anais. [S.l.: s.n.], 1978. v.10.

HAYES-ROTH, F.; WATERMAN, D. A.; LENAT, D. B. (Ed.). **Building expert systems.** London: Addison-Wesley, 1983. p.3-29

HOIS, J.; SCHILL, K.; BATEMAN, J. **Integration Uncertain Knowledge in a Domain Ontology for Room Concept Classifications**. Universität Bremen, Germany, 2007.

HOLI, M.; HYVÖNEN, E. **Modeling Uncertainty in Semantic Web Taxonomies**. University of Helsinki, Finland, 2006.

HUANG, HONG-ZHONG; ZUO, MING J.; SUN, ZHAN-QUAN. **Bayesian reliability analysis for fuzzy lifetime data**. Journal Fuzzy Sets and Systems. vol. 157 Issue 12, p. 1674-1686. 2006.

IBGE. Pesquisa de Orçamentos Familiares 2008-2009. **Antropometria e Estado Nutricional de Crianças, Adolescentes e Adultos no Brasil**. 2010:130. Disponível em: <http://www.ibge.gov.br/home/estatistica/populacao/condicaodevida/pof/default.shtm>. (acesso em 01 de março de 2013).

JANSSEN I, LEBLANC AG. **Systematic review of the health benefits of physical activity and fitness in school-aged children and youth**. Int J Behav Nutr Phys Act. 2010;7:40.

KANDEL, A. **Fuzzy Mathematical Techniques with Applications**. Florida. Addison-Wesley Publishing Company, 1986.

KASABOV, NIKOLA K. **Foundations of neural networks, fuzzy systems and knowledge engineering**. Massachusetts Institute of Technology. 1998.

KATZMARZYK PT, SRINIVASAN SR, CHEN W, MALINA RM, BOUCHARD C, BERENSON GS. **Body mass index, waist circumference, and clustering of cardiovascular disease risk factors in a biracial sample of children and adolescents**. Pediatrics. Aug 2004; 114(2):e198-205.

KITCHENHAM, B. A. **Procedures for Performing Systematic Reviews**. Software Engineering Group – KeeleUniversity - United Kingdom and Empirical Software Engineering, National ICT Australia Ltd. 2004

KONES, RICHARD. **Primary prevention of coronary heart disease: integration of new data, evolving views, revised goals, and role of rosuvastatin in management.** A comprehensive survey. *Drug Design, Development and Therapy* :5 325–380, 2011.

KYULO, NAMGYAL L.; KNUTSEN, SYNNOVE F.; FRASER, GARY E. AND SINGH, PRAMIL N. **Effect of Weight Loss in Adults on Estimation of Risk Due to Adiposity in a Cohort Study Obesity** (2012) 20, 206–213. doi:10.1038/oby.2011.281

LAUDON, K. C.; LAUDON, J. P. **Sistemas de Informação.** Rio de Janeiro: Livros Técnicos e Científicos, 1999.

LOPES, LUIZ FERNANDO; GONÇALVES, ALEXANDRE LEOPOLDO; TODESCO, JOSÉ LEOMAR. **Um Modelo de Engenharia do Conhecimento Baseado em Ontologia e Cálculo Probabilístico voltado ao Processo de Diagnóstico.** VII Congresso Nacional de Excelência em Gestão, 2011.

MAHLER, RONALD P.S. **Combining ambiguous evidence with respect to ambiguous a priori knowledge. Part II: Fuzzy logic.** *Fuzzy Sets and Systems* 75. 319-354. Elsevier. 1995.

MAMDANI, E.H.; GAINES, B.R. **Fuzzy Reasoning and its Applications.** Academic Press Inc., London, England, 1981.

MARQUES, R. L.; DUTRA, I. **Redes Bayesianas: o que são para que servem, algoritmos e exemplos de aplicações.** Rio de Janeiro, 2008.

MATURANA, H.; VARELA, F. **A Árvore do Conhecimento.** Ed. Psy II, 1995.

MAYER, H. C. **Validação de uma base de conhecimento para um sistema especialista bayesiano de apoio ao diagnóstico do risco metabólico.** Dissertação de mestrado em Ciências Médicas – UFSC – Florianópolis, 2012.

MEYER, P. L. **Probabilidade: Aplicações da Estatística.** 2. ed. [S.l.]: LTC, 2000.

MORAIS, R. de. **Filosofia da ciência e da tecnologia: introdução metodológica e crítica**. Campinas: Papirus, 1988.

MORIN, EDGAR. **Introdução ao pensamento complexo**. Ed. Sulina. Porto Alegre, 2005.

MORIN, EDGAR. **O desafio do pensamento complexo**. Tradução: Eliane Lisboa. Porto Alegre, Sulina, 2006.

MULROW, C. D. **Systematic Reviews: Rationale for systematic reviews**. BJM Journals, v.309, 1994.

NAGY, MIKLOS; VARGAS-VERA, MARIA AND MOTTA, ENRICO. **DSSim-ontology mapping with uncertainty**. In: 1st International Workshop on Ontology Matching (OM-2006), Athens, GA, USA, 2006.

NASSAR, S. **Sistemas Especialistas Probabilísticos**. INE. UFSC, Florianópolis, 2012.

NAVEGA, SERGIO. **Epistemologia e Filosofia**. Publicações Digitais Inteliwise. 2002.

NEAPOLITAN, R. E. **Learning Bayesian Networks**. [S.l.]: Prentice-Hall, 2003.

NETICA NORSYS. Disponível em: <norsys.com>. Acesso em: <setembro 2012>.

NONAKA, I., AND KONNO, N. **The Concept of “Ba”: Building a Foundation for Knowledge Creation**. California Management Review (40:3), 1998, pp. 40-54.

NONAKA, I.; TAKEUCHI, H. **Criação de Conhecimento na Empresa**. São Paulo. Ed. Campus, 1997.

NOVAES, JULIANA FARIAS DE; PRIORE, SILVIA ELOIZA; FRANCESCHINI, SYLVIA DO CARMO CASTRO AND LAMOUNIER, JOEL ALVES. **Does the Body Mass Index Reflect Cardiovascular Risk Factors in Brazilian Children?** Journal of Tropical Pediatrics. 1-6, 2012.

NOWOTNY, H. **The Potential of Transdisciplinarity**. Notas de Aula. Metodologia de Pesquisa. Programa de Pós-graduação em Engenharia e Gestão do Conhecimento. UFSC, 2010.

OCDE. **Knowledge-Intensive Service Activities in the Software Industry: Draft Synthesis**. Report of TIP Innovation. Case Studies on KISA, Software Module. Internal working document, 2003.

PAN, HEPING. **Fuzzy Bayesian Network – A General Formalism for Representation, Inference and Learning with Hybrid Bayesian Networks**. Australia, 1999.

PAULINO, C. D.; TURKMAN, M. A. A.; MURTEIRA, B. **Estatística Bayesiana**. Lisboa: Fundação Calouste Gulbenkian, 2003.

PEARL, J. **Probabilistic Reasoning in Intelligent Systems**. Morgan Kauffmann Publishers. San Francisco, 1988.

PEDIATRIA SB. **Avaliação Nutricional da Criança e do Adolescente: Manual de Orientação**. São Paulo: Sociedade Brasileira de Pediatria Departamento de Nutrologia; 2012.

PENZ, C. A. **Procedimentos para prover confiabilidade ao uso de Inteligência Artificial em ensaios de desempenho de compressores herméticos de refrigeração**. Tese de Doutorado. Programa de pós-graduação em Engenharia Mecânica. UFSC. Florianópolis, 2011.

PÉREZ, ASUNCIÓN GÓMEZ; LÓPEZ, M. F.; CORCHO, OSCAR. **Ontological Engineering**. Springer, 2004.

PESSOA JUNIOR, O. **Conceitos de Física Quântica**. 1ª ed. São Paulo. Ed. Livraria da Física, 2003.

PHUA DH, TAN NC. **Cognitive aspect of diagnostic errors**. Ann Acad Med Singapore. 2013 Jan;42(1):33-41.

PIRES, D. F. **Interoperabilidade semântica na troca de informações de segunda opinião diagnóstica**. Tese de Doutorado. USP, 2007.

PIRES, M. M. DE SOUZA. **O processo de Classificação do Risco Metabólico em Crianças e Adolescentes**. Entrevista concedida em 12 de dezembro de 2012. Hospital Universitário de Florianópolis, 2012.

PIRES, M. M. DE SOUZA; NASSAR, S. M. **Redes Bayesianas e o processo de Classificação de Risco Metabólico em Crianças e Adolescentes**. Entrevista concedida em 22 de fevereiro de 2013. UFSC. Florianópolis, 2013.

PRADE, H. **A Computational Approach to Approximate and Plausible Reasoning with Applications to Expert Systems**. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. i. ami-7, n. 3. may 1985.

PREDOIU, L.; Stuckenschmidt, H. **Probabilistic Models for the Semantic Web – A Survey**. University of Mannheim, Germany, 2009.

RAMIREZ, AMELIE G.; DRPH, MPH, GALLION, KIPLING J. MA, CLIFF E. Despres, BJ, REBECCA T. ADEIGBE, MS. **Salud America! A National Research Network to Build the Field and Evidence to Prevent Latino Childhood Obesity**. Am J Prev Med; 44(3S3):S178–S185, 2013.

RAUTENBERG, S.; FILHO, A. C. GOMES; TODESCO, J. L.; GAUTHIER, F. Á. O. **Ferramenta ontoKEM: uma contribuição à Ciência da Informação para o desenvolvimento de ontologias**. Revista Perspectivas em Ciência da Informação. vol. 15, n.1. Belo Horizonte, 2010.

RÖMER, C.; KANDEL, A. **Statistical tests for fuzzy data**. Fuzzy Sets and Systems 72. 1-26. Elsevier, 1995.

ROSEN, KENNETH H. **Matemática discreta e suas aplicações**. 6 ed. São Paulo: McGraw Hill, 2009.

ROSS, TIMOTHY J. **Fuzzy Logic with Engineering Applications**. Universidade do México. McGraw-Hill, Inc, 1995.

RUSSELL, S. J.; NORVIG, P. **Artificial Intelligence: a modern approach**. New Jersey: Prentice Hall, 1995.

SAHAMI, M.. **Learning Limited Dependence Bayesian Classifiers**. In KDD-96: Proceedings of the Second International Conference on Knowledge Discovery and Data Mining, pp. 335-338, Menlo Park, CA: AAAI Press, 1996.

SALMERON, R. A. **Física Moderna**. Centro de Ensino e Pesquisa Aplicada. *e-física*: ensino de física on-line. URL: <http://efisica.if.usp.br/moderna>, 2007.

SANTOS, N. & F. A. P. Fialho. **Análise Ergonômica do Trabalho**. Editora Gênese: Curitiba, 2 ed., 1995.

SANTOS, WILDSON L. P. **Educação Científica e Tecnológica: um compromisso de educadores e cientistas para o desenvolvimento da ciência e tecnologia no Brasil**. Revista Virtual de Gestão de Iniciativas Sociais. ISSN: 1808-6535, 2009.

SAUTER, V. **Decision support systems**. New York: John Wiley & Sons, 1997.

SCHMALHOFER, FRANZ. **Relations between Knowledge Engineering and Cognitive Science: From Import/Export to a Truly Interdisciplinary Knowledge Acquisition Enterprise**. Springer-Verlag Berlim Heidelberg, Germany, 1992.

SCHMITT, V.; TRAVASSOS, L. P.; FIALHO, F. A. P.; REMOR, A. A. M. **Interdisciplinaridade e Pós-graduação**. Revista de Biologia e Ciências da Terra. ISSN: 1519-5228. Vol.6. Nro.2, 2006.

SCHREIBER, G.; WELINGA, B.; HOOG, R. **CommonKADS: A Comprehensive Methodology for KBS Development**. IEEE Expert, 1994.

SCHREIBER, G.; AKKERMANS, H.; ANJEWIERDEN, A.; HOOG, R.; SHADBOLT, N.; DE VELDE, W. V.; AND WIELINGA, B. **Knowledge Engineering and Management: the CommonKADS Methodology**. MIT Press. Cambridge. Massachussets, 2002.

SENGE, P. M. **A quinta disciplina**. São Paulo: Editora Best Seller, 1990.

SHADBOLT, NIGEL; MILTON, NICK. **From Knowledge Engineering to knowledge Management.** British Journal of Management, vol. 10, 309-322, 1999.

SHORTLIFFE, E. **Computer-Based Medical Consultations:** mycin. New York: American Elsevier, 1976.

SKOUTERIS, H.; M. MCCABE, B. SWINBURN, V. NEWGREEN, P. ACHER AND P. CHADWICK. **Parental influence and obesity prevention in pre-schoolers: a systematic review of interventions.** Obesity reviews (2011) 12, 315–328

SMIMOU, K.; BECTOR, C.R.; JACOBY, G. **A subjective assessment of approximate probabilities with a portfolio application.** Research in International Business and Finance 21. 134–160. Elsevier. 2007.

STAMATAKIS E.; Coombs N.; JAGO R.; GAMA A.; MOURÃO I.; NOGUEIRA H.; ROSADO V.; PADEZ C. **Associations between indicators of screen time and adiposity indices in Portuguese children.** Prev Med. 2013 41-8.

STUDER, R. *et. al.*. **Knowledge Engineering: Principles and methods.** Data & Knowledge Engineering, v. 25, n. 1, p. 161-197, 1998.

SU, H. **Multi-source Fuzzy Information Fusion Method Based on Bayesian Optimal Classifier.** Acta Automatica Sinica. vol. 34. Nro. 3. Science Direct. 2008.

SULEMAN, A. **Abordagem Estatística de Conjuntos Difusos.** Edições Sílabo. Lisboa, 2009.

TAHERI, S. M.; BEHBOODIAN, J. **A Bayesian approach to fuzzy hypotheses testing.** Fuzzy Sets and Systems 123, 39–48. Elsevier, 2001.

TAHERI, S.M.; ZAREI, R. **Bayesian system reliability assessment under the vague environment.** Applied Soft Computing 11. 1614–1622. 2011.

TANG, YONGCHUAN; XU, YANG. **Application of fuzzy Naive Bayes and a real-valued genetic algorithm in identification of fuzzy model.** Information Sciences 169. 205–226. Elsevier. 2005

TAYLOR RW, JONES IE, WILLIAMS SM, GOULDING A. **Evaluation of waist circumference, waist-to-hip ratio, and the conicity index as screening tools for high trunk fat mass, as measured by dual-energy X-ray absorptiometry, in children aged 3-19 y.** Am J Clin Nutr. Aug 2000;72(2):490-495.

TIBIRIÇÁ, C. A. G. **Uma abordagem híbrida fuzzy-bayesiana para a modelagem de incertezas.** Dissertação de Mestrado. Curso de Pós-graduação em Ciência da Computação, UFSC. Florianópolis, 2005.

TUOTO, E.A. **Aforismos de Sir William Osler.** In: **História da Medicina By Elvio A Tuoto.** Brasil, 2011.

TURBAN, E.; McLEAN, E.; WETHERBE, J. **Information technology for management.** New York: John Wiley & Sons, 1996.

VIERTL, R. **Is it necessary to develop a Fuzzy Bayesian Inference?** In: R. Viertl (Ed.): Probability and Bayesian Statistics, pp. 471-475. New York: Plenum Publishing Company, 1987.

VIERTL, R. **Statistical methods for fuzzy data.** John Wiley & Sons. New Delhi, India, 2011.

WANG, H.; GAO, X.; Thompson, C.P. **Aircraft Target Recognition Based on Recursive Inference of Fuzzy Discrete DBNs.** IEEE. 2009.

WANG, Y.; LIU, W.; BELL, D. **Combining uncertain Outputs from Multiple Ontology Matchers.** University Belfast, 2008.

WHITAKER RC, WRIGHT JA, PEPE MS, SEIDEL KD, DIETZ WH. **Predicting obesity in young adulthood from childhood and parental obesity.** N Engl J Med. Sep 25 1997;337(13):869-873.

WIDMAN, LAWRENCE E. **Sistemas Especialistas em Medicina.** Revista Informática Médica. Vol.1, Nro. 5 set/out, 1998.

WILLIAMS, E.; WEBER, C. L.; HAWKINS, T. R. **Hybrid Framework for Managing Uncertainty in Life Cycle Inventories**. Journal of Industrial Ecology. Yale University. Vol.13. Nro. 6, 2009.

WILLIAMS, SHEILA M.; GOULDING, AILSA. **Patterns of Growth Associated With the Timing of Adiposity Rebound**. Obesity (2008) 17, 335–341. doi:10.1038/oby.2008.547

World Health Organization W. **Obesity and Overweight**. Disponível em: <http://www.who.int/mediacentre/factsheets/fs311/en/>. Fact sheet N°311. 2011; Updated March 2011 (Acesso em: 01 de março de 2013).

WU, HSIEN-CHUNG. **Fuzzy reliability estimation using Bayesian approach**. Computers & Industrial Engineering 46. 467–493. Elsevier. 2004a.

WU, HSIEN-CHUNG. **Bayesian system reliability assessment under fuzzy environments**. Reliability Engineering and System Safety 83. 277–286. Elsevier. 2004b.

WU, HSIEN-CHUNG. **Fuzzy Bayesian system reliability assessment based on exponential distribution**. Applied Mathematical Modelling 30. 509–530. Elsevier. 2006.

YANG, CHRISTOPHER C. **Fuzzy Bayesian Inference**. IEEE. 0-7803-4053-1/97. 2707-2712. 1997.

YANG, YI; CALMET JACQUES. **OntoBayes: An Ontology-Driven Uncertainty Model**. University of Karlsruhe - Germany, 2005.

YANG, Z.; BONSALL, S.; WANG, J. **Fuzzy Rule-Based Bayesian Reasoning Approach for Prioritization of Failures in FMEA**. IEEE Transactions on Reliability, Vol. 57, Nro.3, September 2008.

ZADEH, LOTFI A. **Fuzzy Sets**. Information and Control. Berkeley, 1965.

ZADEH, LOTFI A. "Fuzzy Sets as the Basis for a Theory of Possibility", Fuzzy Sets and Systems 1:3-28, 1978.

ZADEH, LOTFI A. **Fuzzy Logic, Neural Networks and Soft Computing**. Berkeley, p. 77-84, 1994.

ZHENG, H.; KANG, B.; KIM, H. **An Ontology-based Bayesian Network Approach for Representing Uncertainty in Clinical Practice Guidelines**. Seoul National University. Korea, 2007.

ZIMMERMANN, H. J. **Fuzzy sets theory and its applications**. Boston: Kluwer, 1991.

APÊNDICE A - Resultados da busca com escopo abrangente

Key-Words (Search)	Total	Área do Conhecimento		Fonte da Publicação		Ano da Publicação	
Knowledge Engineering	5118	Environmental Science	338	Journal	250	Até 1997	61
		Business, Management and Accounting	283	Repositories	331	1998	31
		Economics, Econometrics and Finance	282	Patent Offices	83	1999	38
		Computer Science	159	Web	3998	2000	64
		Biochemistry, Genetics and Molecular Biology	96			2001	76
		Agricultural and Biological Sciences	95			2002	92
		Engineering	95			2003	150
		Materials Science	93			2004	173
		Immunology and Microbiology	79			2005	211
		Earth and Planetary Sciences	71			2006	274
		Energy	68			2007	236
		Physics and Astronomy	66			2008	278
		Chemistry	61			2009	396
		Chemical Engineering	58			2010	798
Medicine and Dentistry	38			2011	2004		

		Social Sciences	30		2012 (<i>andamento</i>)	239
		Mathematics	24			
		Decision Sciences	22			
		Neuroscience	10			
		Psychology	9			
		Pharmacology, Toxicology and Pharmaceutical Science	7			
		Veterinary Science and Veterinary Medicine	4			
		Arts and Humanities	2			
		Nursing and Health Professions	2			

APÊNDICE B - Resultados da busca com escopo abrangente acrescentando o termo “*estocástico*”)

Key-Words (Search)	Total	Área do Conhecimento		Fonte da Publicação		Ano da Publicação	
Knowledge Engineering AND Stochastic	674	Business, Management and Accounting	166	Journal	19	Até 1997	6
		Economics, Econometrics and Finance	165	Repositories	199	1998	3
		Computer Science	21	Patent Offices	3	1999	1
		Engineering	13	Web	464	2000	4
		Mathematics	10			2001	10
		Energy	9			2002	12
		Decision Sciences	7			2003	16
		Earth and Planetary Sciences	7			2004	31
		Physics and Astronomy	6			2005	46
		Agricultural and Biological Sciences	5			2006	80
		Biochemistry, Genetics and Molecular Biology	4			2007	39
		Chemical Engineering	4			2008	63
		Environmental Science	4			2009	73
Immunology and Microbiology	4	2010	89				

	Medicine and Dentistry	4	2011	235
	Chemistry	3	2012 <i>(andamento)</i>	28
	Materials Science	3		
	Neuroscience	2		
	Social Sciences	2		
	Pharmacology, Toxicology and Pharmaceutical Science	1		
	Veterinary Science and Veterinary Medicine	1		

APÊNDICE C - Resultados da busca sobre os termos “*Ontologias*” E “*Probabilidade*”

Key-Words (Search)	Total	Área do Conhecimento		Fonte da Publicação		Ano da Publicação	
Ontologies AND Probability	22829	Computer Science	3207	Journal	2614	Até 1997	124
		Biochemistry, Genetics and Molecular Biology	735	Repositories	496	1998	85
		Engineering	658	Patent Offices	750	1999	127
		Immunology and Microbiology	585	Web	17342	2000	127
		Business, Management and Accounting	579			2001	226
		Decision Sciences	486			2002	297
		Economics, Econometrics and Finance	395			2003	496
		Medicine and Dentistry	238			2004	804
		Social Sciences	213			2005	1147
		Mathematics	196			2006	1605
		Agricultural and Biological Sciences	154			2007	1981
		Psychology	136			2008	2291
		Environmental Science	100			2009	2555
		Neuroscience	84			2010	4253
		Energy	75			2011	6272

	Physics and Astronomy	66		2012 (<i>andamento</i>)	1144
	Arts and Humanities	63			
	Earth and Planetary Sciences	50			
	Materials Science	45			
	Pharmacology, Toxicology and Pharmaceutical Science	36			
	Chemical Engineering	34			
	Chemistry	33			
	Nursing and Health Professions	16			
	Veterinary Science and Veterinary Medicine	8			

APÊNDICE D - Conteúdos para análise da revisão sistemática

Identificação do trabalho	Resumo	Abordagem	Principais características	Ano
<p>(I) <i>Fuzzy Bayesian Network – A General Formalism for Representation, Inference and Learning with Hybrid Bayesian Networks.</i> Pan, Heping. <i>Australia.</i></p>	<p>Já discutido na secção (2.7.2). Este trabalho apresenta um formalismo matemático que contribui para os processos de inferência e aprendizado em Redes Bayesianas Híbridas. As <i>HBN</i> são assim denominadas por relacionarem em sua estrutura um misto de variáveis discretas e também de variáveis contínuas. São extensões das Redes Bayesianas mais tradicionais do ponto de vista do estudo da Probabilidade Condicional, as quais modelam somente variáveis discretas. A motivação para a utilização de <i>HBN</i> está associada às demandas de aplicações do mundo real que necessitam deste modelo híbrido. O autor introduz a ideia de utilizar funções de aproximação fuzzy para remodelar a estrutura, a inferência e o aprendizado da rede a partir das variáveis contínuas que esta pode apresentar. Esta contribuição estabelece um novo modelo de Rede Bayesiana Híbrida, as denominadas Redes Bayesianas Fuzzy (<i>FBN</i>) e sugere</p>	<p>Híbrida</p>	<ul style="list-style-type: none"> ▪ Sugere novo formalismo matemático em contribuição aos processos de inferência e aprendizado em Redes Bayesianas Híbridas; ▪ O trabalho é focado em modelagem matemática, desprovido do interesse em demonstrar aplicação em domínios específicos; ▪ Discorre uma atenção especial acerca da complexidade da representação, da inferência e principalmente do aprendizado das Redes Bayesianas Híbridas. O texto do artigo demonstra o envolvimento do trabalho com fatores associados ao estudo da Complexidade Computacional, ou seja, um dos maiores objetivos é mostrar uma solução do ponto de vista algorítmico. Neste caso, 	<p>1999</p>

	<p>dois formalismos diferenciados: a chamada Forma-I que substitui cada variável contínua por uma variável (pai) discreta e adiciona um arco direcionado do nodo-pai discreto ao filho-contínuo. O mapeamento entre estas duas variáveis é realizado por uma aproximação Gaussiana. O modelo gaussiano é uma função de aproximação fuzzy, porém, a Forma I não utiliza todo o formalismo de inferência da lógica difusa; a Forma-II somente substitui cada variável contínua cujos descendentes incluem variáveis discretas por um nodo-pai discreto e também relaciona-os por meio de um arco direcionado. Já o mapeamento neste caso é realizado por meio de Regressão Gaussiana. A Forma-II é mais complexa em termos de processo de inferência e aprendizado da Rede.</p>		<p>parece ser uma pesquisa mais focada aos interesses da análise de complexidade computacional para problemas modelados sob a forma de Redes de Probabilidade;</p> <ul style="list-style-type: none"> ▪ Apesar de o autor denominar esta nova contribuição de <i>FBN</i> (Redes Bayesianas Fuzzy), não foi empregada exaustivamente a Teoria da Lógica Fuzzy. Basicamente, o trabalho concentrou-se no uso do modelo gaussiano como função de aproximação e regressão. 	
	<p>Considerando o fato de que uma ontologia pode incorporar incertezas nos conceitos e relações em sua estrutura de representação de conhecimento, este trabalho propôs a utilização do Cálculo Probabilístico como forma de tratar incertezas intrínsecas na aleatoriedade existente no domínio de ontologias. A</p>		<ul style="list-style-type: none"> ▪ Um trabalho em contribuição a representação de ontologias, caracterizando em especial uma nova forma de propiciar suporte ao processo de raciocínio; ▪ O esquema formal para o processamento da incerteza na ontologia é focado unicamente 	

<p style="text-align: center;">(II)</p> <p><i>A Probabilistic Extension to Ontology language OWL.</i> Ding, Zhongli; Peng Yun. University of Maryland Baltimore Country.</p>	<p>proposta discorre sobre uma extensão de fórmulas de cálculo de probabilidades condicionais adicionada às anotações da OWL. Foram criadas marcações para serem adicionadas a sintaxe da linguagem que permitem com que a inferência e a recuperação da informação de uma ontologia sejam processadas como uma Rede Bayesiana. O autor contextualiza as várias abordagens para processamento de incertezas que podem ser adaptadas às linguagens de representação de ontologias, tais como, <i>Fuzzy Logic, Rough Set Theory, heuristics</i>, porém, concentra-se em modelos probabilísticos, utilizando basicamente a fórmula da Probabilidade Condicional $P(A/B)$. Assim como no trabalho anterior, o autor também cita de forma abrangente o fator complexidade computacional no processamento das Redes Bayesianas. O trabalho menciona a similaridade existente em termos da expressividade dos objetos de estudo empregados na pesquisa: DAG (Grafo Direcionados Acíclicos) de uma Rede Bayesiana com o Grafo RDF de Ontologias em OWL. A sequência de codificação da proposta foi elaborada da</p>	<p>Probabilística</p>	<p>numa abordagem probabilística, utilizando-se como núcleo da inferência, o cálculo de probabilidades condicionais entre as variáveis aleatórias que constituem a estrutura de conhecimento da ontologia, que neste caso, é representada por Redes Bayesianas;</p> <ul style="list-style-type: none"> ▪ O trabalho não denota interesse em tratar obstáculos relacionados à complexidade computacional, bem quanto à Completude no processamento da Rede Bayesiana; ▪ O conteúdo essencial do trabalho, que, na ocasião da publicação, estava em andamento, era disponibilizar uma redefinição de anotações incorporadas em OWL para permitir a representação de Ontologias como Redes de Probabilidades Bayesianas; ▪ No entendimento do autor, fica clara a sua observação quanto à multiplicidade de formas de 	<p>2004</p>
--	--	-----------------------	---	-------------

	<p>seguinte maneira: criar as anotações/marcações probabilísticas a serem inseridas em arquivos OWL, criar as regras para a translação (classes/relações) e por fim, criar as tabelas de probabilidade, a priori, $P(A)$ e as condicionais, $P(A/B)$.</p>		<p>incertezas que podem estar “escondidas” na estrutura e nos relacionamentos semânticos de ontologias. Por isso o autor refere-se a outras teorias para tratamento de incertezas;</p> <ul style="list-style-type: none"> ▪ O trabalho não sugere em qualquer momento uma abordagem híbrida entre diferentes técnicas de tratamento de incertezas que poderiam acarretar em melhorias na acurácia do raciocínio de uma ontologia sob a forma de Rede Bayesiana; ▪ O esquema definido na contribuição desta nova forma de raciocínio em ontologias preserva algumas propriedades e axiomas fundamentais da Probabilidade. 	
	<p>Este trabalho é a tese resultante da proposta apresentada pelo autor em seu artigo anterior (<i>A Probabilistic Extension to Ontology language OWL</i>). Neste, Zhongli Ding apresenta, na forma prototipada, um <i>Framework</i> teórico que denominou de <i>BayesOWL</i>. O <i>framework</i> consiste em três</p>		<ul style="list-style-type: none"> ▪ Trabalho com o formalismo teórico consolidado a partir da proposta apresentada sumariamente no artigo anteriormente publicado pelo autor; 	

<p>(III) <i>Bayes OWL: A Probabilistic framework for Uncertainty in Semantic Web.</i> Ding, Zhongli. University of Maryland Baltimore Country.</p>	<p>componentes chaves: 1 – uma representação de restrições probabilísticas como declarações em OWL; 2 – um conjunto de regras de tradução e procedimentos que convertem uma Rede Bayesiana em uma ontologia OWL; 3 – um método <i>SD-IPFP</i>, que é uma derivação do <i>IPFP</i>, que incorpora restrições de probabilidade e disponibiliza-as dentro de tabelas (probabilidades condicionais) para a Rede Bayesiana mapeada sob a forma de ontologia em OWL. Importante salientar que nesta proposta, o processo de translação preservou a semântica original da estrutura de conhecimento.</p>	<p>Probabilística</p>	<ul style="list-style-type: none"> ▪ O projeto do <i>Framework</i> proposto envolveu diversas outras ferramentas tais como: Jena (uma versão Java), Pellet, Netica da Norsys Software, uma ferramenta para construção de Redes Bayesianas de variáveis discretas, e alguns outros softwares empregados na classificação de textos, uma das atividades utilizadas pelo autor para a validação de sua proposta; ▪ O autor discorre sobre o emprego de <i>BayesOWL</i> em motores de busca para a Web Semântica; ▪ Ao retratar as características de sua versão prototipada, o autor evidencia algumas preocupações quanto à capacidade de motores de inferência <i>BayesOWL</i> suportarem aprendizado e raciocínio quando do cruzamento de duas ou mais ontologias diferentes e sugere maior investigação quando a Escalabilidade do software de translação das Redes Bayesianas 	<p>2005</p>
--	---	-----------------------	--	-------------

			<p>para representações ontológicas;</p> <ul style="list-style-type: none"> ▪ Em seu trabalho, o autor preocupou-se com as inconsistências oriundas da incompletude das restrições probabilísticas sobre as entidades e relações em ontologias. Seu modelo lida com estas probabilidades inconsistentes. <i>BayesOWL</i> pode especificar distribuições de probabilidade que podem satisfazer todas as restrições. 	
	<p>O trabalho consiste em mais uma contribuição à representação, aprendizado e raciocínio em ontologias probabilísticas. O autor direciona sua proposta focando desde o início as limitações das atuais tecnologias da Web Semântica para lidar com incertezas e propõe um formalismo denominado de PR-OWL como forma de implementar a capacidade de uma ontologia para a Web Semântica trabalhar com o raciocínio plausível. Trata-se de mais uma extensão dada a OWL para propiciar o raciocínio sobre probabilidades que representam o conhecimento intrínseco nas relações</p>		<ul style="list-style-type: none"> ▪ Proposta de mais um esquema formal disponibilizado sob a forma de implementação prototipada para contribuir com o incremento da capacidade das ontologias para Web Semântica; ▪ A chamada PR-OWL é uma forma de propiciar a capacidade de processar incertezas por meio do raciocínio plausível; ▪ Este trabalho não apresenta qualquer similaridade em termos da originalidade das idéias 	

<p style="text-align: center;">(IV)</p> <p><i>Bayesian Semantics for the Semantic Web.</i> Costa, Paulo Cesar G. George Mason University.</p>	<p>entre as entidades de um determinado domínio em ontologia na Web Semântica. A PR-OWL mantém a compatibilidade de sua linguagem básica (OWL) e, segundo o autor, vai além da lógica clássica determinística, tendo sua semântica formal baseada em MEBN (<i>Multi-Entity Bayesian Networks</i>). Redes Bayesianas multi-entidade integram Lógica de Primeira Ordem com Probabilidades Bayesianas. A Lógica em MEBN expressa o conhecimento probabilístico como uma coleção de fragmentos MEBN, (MFrag). Um MFragment representa uma distribuição de probabilidade condicional das instâncias das variáveis aleatórias dados os valores das ocorrências de seus pais nos grafos que representam o MFragment e dadas as restrições do contexto. Uma coleção de MFrags representa uma distribuição de probabilidade conjunta sobre um número ilimitado, possivelmente infinito, de instâncias de suas variáveis aleatórias. O autor afirma que até o momento da realização da pesquisa ainda não existia uma implementação plena de MEBN.</p>	<p>Probabilística</p>	<p>introduzidas pelos trabalhos anteriormente analisados, contudo, em muitas definições e argumentações refere-se ao trabalho introduzido por Zhongli Ding;</p> <ul style="list-style-type: none"> ▪ Apesar da observação acima, na proposta o autor também recorre ao formalismo já consolidado da Teoria das Redes de Probabilidade Bayesiana e evidencia o diferencial de seu trabalho pelo emprego das MEBN como sendo extensões das Redes Bayesianas Clássicas, porém, com capacidades adicionais em termos de número de elementos a serem processados e, em especial, a incorporação do suporte matemático da Lógica de Primeira Ordem; ▪ Em termos operacionais, também utiliza marcações aditivas a OWL/RDF para representar conhecimento derivado de raciocínio plausível nas relações semânticas; 	<p>2005</p>
---	--	-----------------------	---	-------------

			<ul style="list-style-type: none"> ▪ O trabalho não sugere qualquer hibridismo a partir do uso de múltiplas técnicas para processamento de incertezas, é focado único e exclusivamente no raciocínio plausível. 	
<p style="text-align: center;">(V)</p> <p><i>Modeling Uncertainty in Semantic Web Taxonomies.</i> <i>Holi, Markus; Hyvönen, Eero.</i> <i>University of Helsinki, Finland.</i></p>	<p>Motivado pelo fato de que ontologias na Web Semântica são baseadas em Lógica Crisp e são desprovidas de mecanismos para lidar com incertezas, o autor propôs um novo esquema formal que combina o cálculo probabilístico de uma Rede Bayesiana com o que denomina de <i>Overlap</i> ou graus de sobreposição de conceitos de uma classe. Utiliza como cenário para submissão e validação da proposta um conjunto de nomes de continentes, países e uma espécie de grau de pertinência de um país a um continente. O autor utiliza um Diagrama de Venn particionado que serve para acomodar continentes e países, que são conceitos de sua ontologia, a partir de uma escala numérica inteira que representa a dimensão do país ou continente. Por meio do Diagrama de Venn é possível perceber as sobreposições nas relações de</p>	<p>Probabilística</p>	<ul style="list-style-type: none"> ▪ No que refere-se ao tratamento de incertezas para a recuperação de informações esta proposta apresenta, aparentemente, uma idéia original, embora busque o suporte da consolidada teoria do cálculo probabilístico e a eficiência das Redes Bayesianas para a propagação de probabilidades; ▪ O conceito de <i>Overlap</i> e sua aproximação a uma probabilidade condicional é um formalismo teórico singular se comparado às demais propostas e suas correlações referenciais; ▪ O modelo não sugere um hibridismo de técnicas, pois não modifica a forma primitiva de inferência bayesiana, mas, um 	<p>2006</p>

	<p>pertinência destes conceitos. A partir de então, um algoritmo calcula o <i>Overlap</i> dos conceitos da taxonomia proposta, sendo que, o valor é compreendido no intervalo $[0,1]$. Este fator numérico, como sendo um coeficiente de relação semântica por aproximação é calculado em termos de probabilidades condicionais. O esquema usa RDF para representação da taxonomia, contudo, diferentemente de outros trabalhos já analisados nesta revisão, este não modifica ou inclui novas marcações em RDF para anotar probabilidades. Em sua discussão e análise o autor compreende a existência de outras formas de se tratar incertezas ou informações vagas, como a Lógica Fuzzy e <i>Rough Sets</i>. Ele critica a arbitrariedade dos valores numéricos utilizados pela modelagem Fuzzy e argumenta a impossibilidade de utilizá-la neste propósito. Parecem ocorrer conflitos entre graus de pertinência de conceitos difusos com o coeficiente <i>Overlap</i> utilizado para sustentar os valores de tabelas de probabilidade usados pela Rede Bayesiana. Situações mais realistas podem ter sua representação dificultada se representadas por Diagramas de Venn.</p>		<p>mapeamento do conceito <i>Overlap</i>, como sendo um grau de sobreposição de conceitos nas relações semânticas de uma taxonomia, para um modelo determinístico;</p> <ul style="list-style-type: none">▪ É uma proposta focada para uma aplicação de demonstração aparentemente muito restrita não estendendo-se a casos mais complexos de representação do conhecimento acerca do mundo real. Além disso, o ponto de partida para a obtenção de coeficientes <i>Overlap</i> é a construção de representações conceituais por meio de Diagramas de Venn;▪ Apesar da crítica e da não adoção de modelagem fuzzy pelo autor, parece haver alguma similaridade entre o conceito de <i>Overlap</i> e o grau de pertinência obtido por funções difusas na Teoria da Possibilidade Fuzzy. É oportuno refletir acerca da similaridade entre um grau de <i>Overlap</i> de dois conceitos de uma classe com o	
--	---	--	---	--

			<p>grau de imprecisão deste conceito em relação a esta classe. A influência desta imprecisão pode afetar consideravelmente a distribuição das probabilidades propagadas na Rede Bayesiana.</p>	
<p>(VI)</p> <p><i>Integration Uncertain Knowledge in a Domain Ontology for Room Concept Classifications.</i> <i>Hois, Joana; Schill, Kerstin; Bateman, John.</i> <i>Universität Bremen, Germany.</i></p>	<p>O trabalho consiste em mais uma integração de abordagens para lidar com incertezas em uma ontologia de domínio. Diferentemente dos trabalhos anteriormente analisados, o autor recorre a Teoria de Dempster-Shafer como sendo uma alternativa para tratar incertezas por meio da utilização de uma Função de Crença (Belief Function). A Teoria de Dempster-Shafer é derivada dos estudos da Probabilidade. Porém, ao invés de associar medidas de probabilidade às proposições, associa um grau de crença a incerteza existente no conhecimento em questão. Estas crenças podem ser associadas não somente às proposições individuais como também a conjuntos de proposições. Uma das maiores vantagens da utilização da Teoria de Dempster-Shafer é a capacidade de se representar o fator “ignorância”. O trabalho foi desenvolvido com foco em um objetivo bem definido, baseado no problema da</p>	Híbrida	<ul style="list-style-type: none"> ▪ Trabalho desenvolvido com foco em aplicação específica para classificação de termos em uma ontologia de domínio; ▪ Diferentemente de outros trabalhos, este recorre a Teoria de Dempster-Shafer para representar as incertezas do domínio em questão; ▪ Não se trata de um formalismo exaustivo, contudo, resolve o propósito; ▪ Reconhece o valor do emprego da Teoria das Redes Bayesianas e da Lógica Fuzzy como abordagens para lidar com incertezas em ontologias, porém, sugere que estas são amplas e com formalismo generalizado para aplicações do mundo real, logo, 	2007

	<p>determinação da relação entre conceitos sobre Classificação de Espaços (Room Concept Classifications). A implementação desta combinação a partir da construção de uma ontologia de domínio e a definição de funções de crença da Teoria de Dempster-Shafer, permitiu a busca por respostas às questões tais como: “Onde posso encontrar um espaço desocupado?” ou “Diga-me quais são todas as possíveis salas para a realização de seminários que tenham ao menos um projetor de vídeo e um quadro-branco?”. Um apontamento interessante das conclusões deste trabalho foi o autor referir-se à proposta desenvolvida por Zongli Ding, já discorrida anteriormente, onde o autor usará também da combinação de Ontologias com engenharia de raciocínio suportada por modelos probabilísticos, porém, enfatiza que neste caso, a proposta de Zongli Ding é mais como contribuição teórica, enquanto neste, o propósito maior foi atender uma necessidade específica de classificação de termos.</p>		<p>sua proposta em usar Dempster-Shafer coube à dimensão do problema de classificação.</p>	
	<p>O artigo retrata o desenvolvimento de uma aplicação experimental para suportar o processo de decisão médica no</p>		<ul style="list-style-type: none"> ▪ O trabalho é motivador por evidenciar a ampla demanda da utilização de Sistemas de 	

<p style="text-align: center;">(VII)</p> <p><i>An Ontology-based Bayesian Network Approach for Representing Uncertainty in Clinical Practice Guidelines.</i> Zheng, Hai-tao; Kang, Bo-Yeong; Kim, Hong-Gee. Seoul National University. Korea.</p>	<p>acompanhamento de terapias clínicas. Os denominados CPGs (Clinical Practice Guidelines) são intensamente utilizados por médicos e lidam com inúmeras situações em que o contexto das relações entre as variáveis apresentam incertezas. No âmbito da decisão médica perante o tratamento de um paciente são muitas variáveis incertas que afetam diretamente o sucesso de uma terapia. O conhecimento sobre o quadro clínico do paciente e os efeitos adversos que podem ocorrer sob sua saúde é fundamental na atividade clínica. O autor descreve algumas ferramentas que facilitam o compartilhamento de <i>Guidelines</i> clínicos, tais como, o SAGE (<i>Standards-based Sharable Active Guideline Environment</i>) como sendo um <i>guideline</i> para a interoperabilidade da codificação de conteúdos para <i>guidelines</i> clínicos e o GLIF, um padrão baseado na Web Semântica para representar estes <i>guidelines</i> clínicos. SAGE e GLIF executam ontologias por meio de funções disponibilizadas nos CIS (<i>Clinical Information System</i>). Em processos clínicos, como no caso, do tratamento de diabéticos, inúmeras são as incertezas</p>	<p>Probabilística</p>	<p>Conhecimento no suporte ao processo decisório clínico;</p> <ul style="list-style-type: none"> ▪ Estes processos caracterizam cenários de muita incerteza; ▪ Mais um trabalho que foca o uso das Redes Bayesianas e o raciocínio plausível para inferir sobre a representação de conhecimento estruturado por ontologias; ▪ É oportuno ressaltar que trabalhos como este, voltados às demandas da área clínica, demonstram de certa forma, uma facilidade na validação de suas propostas e modelos para este domínio de aplicação em virtude da vasta base de dados e da participação e envolvimento dos especialistas humanos (médicos) no processo de construção dos Sistemas de Conhecimento; ▪ Uma contribuição da análise deste artigo foi conhecer o padrão GLIF citado pelo autor. 	<p>2007</p>
--	--	-----------------------	---	-------------

	<p>que podem surgir, tais como: dados inalcançáveis (histórico de diabetes na família), dados ainda não coletados (níveis de glicose), entre outros. O objetivo do trabalho então foi desenvolver uma abordagem para representar incertezas em CPGs e auxiliar médicos a decidirem o risco destas incertezas no processo clínico. A modelagem também utilizou as Redes Bayesianas para inferirem nas relações incertas da ontologia empregada. A validação da proposta foi realizada com um cenário criado a partir da terapia a base de aspirina para pacientes diabéticos.</p>			
<p>(VIII) <i>Combining uncertain Outputs</i></p>	<p>O trabalho consiste na combinação de múltiplas ontologias e de uma abordagem híbrida para lidar com as incertezas a partir da necessidade de se efetuar combinação entre termos. O formalismo proposto aqui empregou a Teoria da Evidência (Dempster-Shafer) com a Teoria da Possibilidade (Fuzzy Logic). O autor utilizou três formas diferentes de realizar a combinação de termos de múltiplas ontologias, os quais são: Edit distance-based matcher, que compara o</p>		<ul style="list-style-type: none"> ▪ Trata-se de uma modelagem focada para um problema específico, ou seja, a combinação de termos na junção de múltiplas ontologias; ▪ O trabalho empregou a Teoria de <i>Dempster-Shafer</i> e a Teoria da Possibilidade (<i>Fuzzy Logic</i>); ▪ O hibridismo não foi uma integração de abordagens para 	

<p><i>from Multiple Ontology Matchers.</i> <i>Wang, Ying; Liu, Weiru; Bell, David.</i> <i>University Belfast.</i></p>	<p>grau de similaridade entre dois termos a partir de processamento sobre strings, Linguistic-based matcher, recorre a tesouros para combinar palavras, uma forma, segundo o autor, amplamente explorada em muitos outros artigos. Para este tipo de combinação foi utilizado o software WordNet, uma base de dados léxica desenvolvida pela Princeton University. Ao empregar a Lógica Fuzzy, o autor considerou a medida de similaridade entre termos como sendo o grau de possibilidade calculado por meio do operador normalizado mínimo, uma função amplamente utilizada no processo de inferência e transformação Fuzzy→Crisp. O autor considerou em uma vantagem da Teoria da Possibilidade sobre Dempster-Shafer em seu propósito de determinar o fator similaridade para a combinação de termos.</p>	<p>Híbrida</p>	<p>tratamento de incertezas existentes em ontologias, mas, uma comparação entre a eficiência das duas abordagens no que refere-se à determinação da similaridade entre termos contidos em múltiplas ontologias;</p> <ul style="list-style-type: none"> ▪ Apesar de o trabalho citar o uso da Teoria da Possibilidade, ficou evidente que não foi utilizado todo o formalismo da Lógica Fuzzy, mas somente uma função de distribuição de possibilidade dada pelo operador <i>mínimo</i> na obtenção do cálculo da medida de similaridade; ▪ O autor recomenda a exploração de outras teorias para lidar com incertezas no âmbito do mapeamento de ontologias. 	<p>2008</p>
	<p>Neste trabalho o autor propôs uma revisão e análise de vários modelos probabilísticos empregados no tratamento de incertezas em aplicações da web Semântica. Ele enfatiza inicialmente que a Estatística e as Ontologias provêem muitos insights para o compartilhamento</p>		<ul style="list-style-type: none"> ▪ O artigo é uma análise e discussão acerca de outros trabalhos e artigos originais cujas abordagens, técnicas e ferramentas são apresentadas sobre o contexto do tratamento 	

<p>(IX) <i>Probabilistic Models for the Semantic Web – A Survey.</i> <i>Predoiu, Livia; Stuckenschmidt, Heiner.</i> <i>University of Mannheim, Germany.</i></p>	<p>de dados na Web Semântica e atribui este fato em virtude da Web caracterizar-se por um ambiente com informações incompletas, inconsistentes e vagas. O autor buscou as diferentes técnicas existentes que possam suportar: 1) a representação de conhecimento inerente à incerteza da informação; 2) o aprendizado de ontologias; 3) a classificação de documentos na Web; 4) a combinação de ontologias; 5) o mapeamento de ontologias usado para a Integração da Informação. Faz uma análise das linguagens para Web Semântica, em especial, RDF e OWL e dos formalismos utilizados para estender estas linguagens aos propósitos apresentados pelas abordagens de outros autores. Os modelos probabilísticos levantados e discutidos pelo autor foram: 1) as Redes Bayesianas (BNs); 2) a Programação Lógica Bayesiana (BLPs): esta foi uma primeira referência encontrada sobre uma extensão das Redes Bayesianas combinadas com o denominado Modelo Herbrand, um formalismo da Lógica de Primeira Ordem para verificar a aceitabilidade de um conjunto de cláusulas na representação</p>	<p>Probabilística</p>	<p>probabilístico de incertezas na Web Semântica;</p> <ul style="list-style-type: none"> ▪ Nota-se o círculo de referências e citações dos trabalhos desenvolvidos neste âmbito, ou seja, reflete a existência de grupos bem concentrados de pesquisadores trabalhando nesta temática e com desafios similares; ▪ O autor não traz qualquer referência sobre o tratamento da incerteza associada ao fator imprecisão existente no conhecimento representado por ontologias; ▪ Assim como em outros artigos, o autor aponta em suas considerações conclusivas o problema da Representação de Probabilidades Cíclicas, o que parece ser mais um desafio em termos de pesquisas no campo da Ciência da Computação e da capacidade e eficiência das linguagens formais poderem processar grafos com 	<p>2009</p>
--	--	-----------------------	--	-------------

	<p>de uma linguagem formal. Conforme conclui o autor, não se tem publicações acerca de resultados mais complexos com esta abordagem e somente uma ferramenta foi implementada para este tipo de raciocínio, o Balios Engine por (Kersting & Dick, 2004); 3) a Lógica de Escolha Independente (ICL); 4) as Redes Bayesianas Multi-entidades (MEBNs); 5) os Datalogs Probabilísticos. Também, as linguagens discutidas no artigo foram: a) as extensões de RDF para a representação de Probabilidades; b) as extensões da OWL, detalhando sobre a PR-OWL e a BayesOWL, ambas já relatadas neste trabalho pela revisão de outros artigos para os quais se faz novas referências. Para cada linguagem o autor analisa a sua Expressividade, o Raciocínio e a Eficiência conjugados e a Aplicabilidade na Integração de Informações. Uma importante observação conclusiva do autor foi não ter encontrado em qualquer uma destas abordagens a capacidade do formalismo ou da ferramenta lidar com representações de probabilidades cíclicas.</p>		<p>complexidade NP. Esta barreira pode estar impedindo avanços na elaboração e aplicação de formalismos teóricos para modelos determinísticos.</p>	
	<p>Esta é a tese resultante da continuidade das pesquisas de Carvalho já iniciadas na</p>		<ul style="list-style-type: none"> ▪ Apesar de o trabalho incrementar a proposta da PR-OWL para lidar 	

<p style="text-align: center;">(X)</p> <p><i>Probabilistic Ontology: Representation and Modeling Methodology.</i> Carvalho, Rommel Novaes. George Mason University.</p>	<p>elaboração de sua dissertação de mestrado sobre o aperfeiçoamento das técnicas para a representação probabilística de ontologias. A essência do trabalho foi estender a proposta da PR-OWL para uma PR-OWL 2. Em sua nova contribuição o autor incrementou os aspectos sintáticos e semânticos definidos na PR-OWL 2 para promover compatibilidades entre PR-OWL e a própria forma primitiva da OWL. Além desta extensão o trabalho do autor consistiu em apresentar uma nova metodologia para a construção de Ontologias Probabilísticas que denomina de Modeling Process for Semantic Technologies (UMP-ST), com o implemento de facilidades para o próprio modelador da ontologia. A validação de sua nova metodologia, das ferramentas teóricas e de simulação foi realizada por meio de testes sobre duas diferentes ontologias: uma para identificação de fraudes em procurações públicas no Brasil e outra para identificar a ameaça de terrorismo em domínio marítimo. Como uma continuidade da PR-OWL, o autor afirma que sua nova abordagem reúne o suporte para o raciocínio sobre os</p>	<p>Probabilística</p>	<p>com a representação de probabilidades em ontologias, continua focando apenas em um tipo de incerteza, ou seja, a aleatoriedade presente no domínio da ontologia;</p> <ul style="list-style-type: none"> ▪ O autor concentrou-se no formalismo teórico e na validação por meio de simulações, uma ferramenta para implementar tal metodologia ainda não foi construída; ▪ Um dos maiores desafios da proposta da PR-OWL 2 por meio da UMP-ST é a escalabilidade do esquema formal perante a complexidade da ontologia; ▪ Em suas sugestões para trabalhos futuros o autor não demonstra interesse em investigar as influências semânticas sobre o raciocínio da PR-OWL 2 quando o domínio da ontologia apresentar incerteza por imprecisão. 	<p>2011</p>
--	---	-----------------------	--	-------------


	<p>principais tipos de incertezas que podem ser tratadas por uma Lógica de Primeira Ordem Probabilística, em especial pela capacidade de associar variáveis randômicas com indivíduos, classes e propriedades.</p>			
<p>(XI) Um Modelo de Engenharia do Conhecimento Baseado em Ontologia e Cálculo Probabilístico voltado ao Processo de Diagnóstico. Lopes, Luiz Fernando; Gonçalves, Alexandre</p>	<p>O autor propôs uma combinação da abordagem probabilística e das ferramentas de pesquisa literária para contribuir com o processo de aquisição de novos conhecimentos utilizados em processos de diagnóstico médico. A arquitetura para o modelo utiliza o software Protégé para estruturar a ontologia, o software Netica Norsys para desenvolver a Rede Bayesiana que fará o cálculo probabilístico sobre as incertezas da ontologia e a ferramenta Bitola que providencia a pesquisa literária através das predicções semânticas e regras de associação. Basicamente, o modelo é dirigido e validado sobre um domínio que</p>	<p>Híbrido</p>	<ul style="list-style-type: none"> ▪ Trata-se de uma nova abordagem em contribuição ao tratamento de incertezas presentes em ontologias; ▪ Utiliza software de revisão de texto juntamente com o cálculo probabilístico, como sendo um processo de KDD, para gerar um novo conhecimento a ser incorporado na ontologia; ▪ Em sua revisão, o autor faz referência a Modelagem Fuzzy como forma de processar os dados clínicos de pacientes e 	<p>2011</p>

<p>Leopoldo; Todesco, José Leomar. VII Congresso Nacional de Excelência em Gestão.</p>	<p>envolve as entidades: paciente, sintoma, laboratório e evidência. Durante o processo de simulação usando o raciocinador Pellet da ontologia, verificou-se que determinado paciente ficou sem um diagnóstico conclusivo devido ao fato dos dados informados ao sistema serem insuficientes ou incertos e a subjetividade nas observações representadas pelos dados ocasionaram esta deficiência na resposta do diagnóstico. Logo, a Rede Bayesiana modelada propiciou, por meio do cálculo probabilístico, um diagnóstico com resultado mais plausível.</p>		<p>gerar conhecimento em diversos níveis de granularidade de acordo com a profundidade do diagnóstico. Contudo, em sua proposta não utiliza qualquer componente teórico oriundo da Teoria da Lógica Fuzzy;</p> <ul style="list-style-type: none"> ▪ Também não releva preocupação e/ou interesse em investigar o conhecimento impreciso descoberto nas bases de dados ou arquivos literários. 	
<p>(XII) <i>Fuzzy ontology representation using OWL 2.</i> Bobillo, Fernando; Straccia, Umberto. <i>International Journal of</i></p>	<p>Em conformidade com outros trabalhos que discorrem sobre a problemática das incertezas presentes em ambientes dinâmicos, este artigo apresenta um novo paradigma de interpretação destas incertezas intrínsecas em domínios de ontologias, contudo, caracterizado pela imprecisão, vagueza ou incompletude das informações. Assim como nas abordagens probabilísticas ou híbridas a proposta é modificar alguns aspectos sintáticos da linguagem OWL de modo a introduzir anotações que fomentem a representação e a recuperação de conceitos difusos. O</p>	<p>Possibilística</p>	<ul style="list-style-type: none"> ▪ O trabalho elucida a incerteza por imprecisão; ▪ É uma abordagem diferente da probabilística para raciocinar em domínios com sobreposição semântica de conceitos sobre relações; ▪ Uma medida de incerteza fuzzy é interpretada por um grau de verdade na pertinência de um elemento (entidade) a um conjunto (classe), ou seja, o quão 	<p>2011</p>

<p><i>Approximate Reasoning.</i> <i>Elsevier Published.</i></p>	<p>trabalho é derivado e inspirado em outras obras que introduziram esquemas formais da denominada Fuzzy Description Logic. Basicamente, a linguagem OWL é suportada pela matemática da DL e estas modificações para a OWL 2 acarretaram em uma redefinição da DL para uma DL Fuzzy. OWL 2 tem a capacidade de lidar com esquemas hierárquicos de classes e conceitos difusos, bem como realizar inferências a partir de relações difusas. De acordo com os pressupostos elementares da Teoria da Possibilidade de Lofti Zadeh, a incerteza sobre um conceito vago ou impreciso é representada por coeficientes $u(x)$ no intervalo $[0,1]$, denotados por um grau de verdade ou grau de pertinência em uma relação de classes. É uma contraposição à incerteza probabilística que está associada à casualidade ou a aleatoriedade presente nas relações conceituais. Neste artigo, o autor discorre exaustivamente sobre o formalismo da Lógica Fuzzy para mostrar o mapeamento deste formalismo às inserções DL introduzidas na OWL 2. Basicamente, o esquema RDF foi amplamente utilizado. O trabalho mostrou de forma generalizada</p>		<p>uma classe relaciona-se com outra, o que difere da pergunta: qual a chance de uma classe estar relacionada com outra? Esta é respondida por um raciocinador probabilístico;</p> <ul style="list-style-type: none"> ▪ Apesar da similaridade do coeficiente de pertinência fuzzy ficar compreendido no intervalo $[0,1]$ com uma medida de incerteza probabilística que também é definida em termos naturais 0 ou 1, esta por sua vez refere-se à confirmação ou não de um evento ou evidência observada. E para isso, o fator 1 refere-se ao valor True e 0 refere-se ao valor False, da confirmação do evento casual em um espaço de hipóteses aleatórias; ▪ Este artigo mostrou a aceitabilidade e viabilidade da modificação de RDF/OWL para também suportar a representação da imprecisão, permitindo que raciocinadores fuzzy possam inferir soluções para certos 	
---	--	--	--	--

	algumas aplicações e evidenciou a necessidade da criação de ferramentas MCDM (Multi-criteria decision making). Simulações foram realizadas por meio da construção de plugins para o software Protégé.		problemas do mundo real representados por ontologias.	
--	---	--	---	--

APÊNDICE E - Autores mais citados do conjunto de 40 artigos selecionados



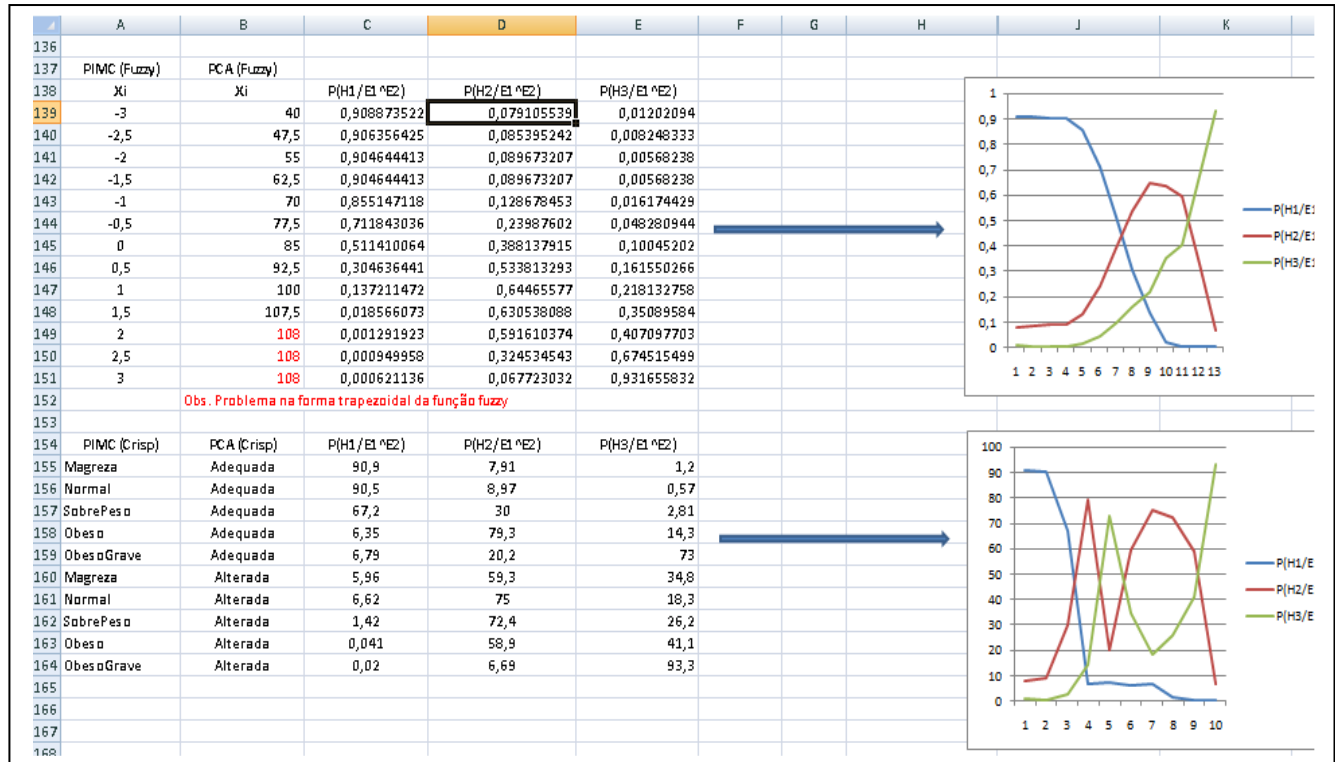
**APÊNDICE F – Extratos da planilha utilizada para simulações do Modelo de Inferência Fuzzy-Bayesiano:
Base de Conhecimento – dados da Rede Bayesiana Clássica**

	A	B	C	D	E	F
1	REDE BAYESIANA - CLÁSSICA					
2						
3	TABELAS DE PROBABILIDADES (BASE DE CONHECIMENTO)					
4						
5	RISCO METABOLICO (HIPÓTESES-SAÍDA)					
6	ESTADO (H_i) PROB. PRIORI (%)					
7	Baixo	35%				
8	Moderado	34%				
9	Elevado Grave	31%				
10						
11	PIMC (EVIDÊNCIA-1 --> PERFIL DO ÍNDICE DE MASSA CORPÓREA)					
12	H _i /E _i , ^k	Magreza	Normal	SobrePeso	Obeso	ObesoGrave
13	Baixo	20,50%	60%	18%	1%	0,50%
14	Moderado	6%	20%	27%	42%	5%
15	Elevado Grave	3%	4,17%	8,33%	25%	59,50%
16						
17						
18	PCA (EVIDÊNCIA-2 --> PERFIL DE CIRCUNFERÊNCIA ABDOMINAL)					
19	H _i /E _i , ^k	Adequada	Alterada			
20	Baixo	98%	2%			
21	Moderado	30%	70%			
22	Elevado Grave	10%	90%			
23						
24						
25	HEREDITARIEDADE(EVIDÊNCIA-3)					
26	H _i /E _i , ^k	Nenhum	Pai_ou_Mae	Ambos		
27	Baixo	80%	14,29%	5,71%		
28	Moderado	10%	60%	30%		
29	Elevado Grave	3%	30%	67%		
30						
31						
32	PPA (EVIDÊNCIA-4 --> PERFIL DE PRESSÃO ARTERIAL)					
33	H _i /E _i , ^k	Normal	Pre_hipertensao	Hipertensao		
34	Baixo	94,29%	5,71%	0%		
35	Moderado	73,53%	17,65%	8,82%		
36	Elevado Grave	66,67%	12,50%	20,83%		
37						
38						

APÊNDICE G – Extratos da planilha utilizada para simulações do Modelo de Inferência Fuzzy-Bayesiano: modelagem da imprecisão – configuração de parâmetros das funções de pertinência fuzzy

H	I	J	K	L	M
MODELAGEM DA IMPRECISÃO SOBRE AS EVIDÊNCIAS					
PIMC (Adolescentes)		<i>Entrada Xi==></i>	3,5		
Suporte/E_{i,k}^z--> (Escore z) = [-3,+3]		<u>Magreza</u>	<u>Normal</u>	<u>SobrePeso</u>	<u>Obeso</u>
Parâmetros \hat{N} -LINEARES					
a		2	-1	1,75	2,5
b		<i>t</i>	0,8	0,8	0,8
c		-2	<i>t</i>	<i>t</i>	<i>t</i>
d		<i>t</i>			
$\mu(X_i)$		0,0	0,0	0,1	0,5
		<i>Sig. Inversa</i>	<i>Gauss</i>	<i>Gauss</i>	<i>Gauss</i>
PCA --> PERFIL DE CIRCUNFERÊNCIA ABDOM		<i>Entrada Xi==></i>	59,5		
Suporte/E_{i,k}^z--> (cm) = [50,110]		<u>Adequada</u>	<u>Alterada</u>		
Parâmetros \hat{N} -LINEARES					
a		0,5	0,5		
b		<i>t</i>	<i>t</i>		
c		60	60		
d		<i>t</i>	<i>t</i>		
$\mu(X_i)$		0,6	0,4		
HEREDITARIEDADE (Obs: É considerada CRISP, não influencia P(Hife))					

APÊNDICE H – Extratos da planilha utilizada para simulações do Modelo de Inferência Fuzzy-Bayesiano: propagação de resultados com a aplicação das fórmulas de inferência



APÊNDICE I – Extratos da planilha utilizada para simulações do Modelo de Inferência Fuzzy-Bayesiano: dados provenientes do especialista

SOMA			
A	B	C	D
70			
71 Simulação - dados do especialista 1			
72			
PIMC (Fuzzy)	PCA (Fuzzy)		
Xi	Xi	P(Baixo/Pimc=Fuzzy*PCA=Fuzzy*AFS=Crisp*HERE=Crisp*PPA=Crisp)	P(Moderado/Pimc=Fuzzy*PCA=Fuzzy*AFS=Crisp*HERE=Crisp*PPA=Crisp)
2,34	84	0,005270804	0,221895809
$=(((\$B\$13*A92+\$C\$13*B92+\$D\$13*C92+\$E\$13*D92+\$F\$13*E92)*(\$B\$20*F92+\$C\$20*G92)*\$C\$41*\$B\$27*\$B\$34*\$B\$7)/((((\$B\$13*A92+\$C\$13*B92+\$D\$13*C92+\$E\$13*D92+\$F\$13*E92)*(\$B\$20*F92+\$C\$20*G92)*\$C\$41*\$B\$27*\$B\$34*\$B\$7)/((((\$B\$13*A92+\$C\$13*B92+\$D\$13*C92+\$E\$13*D92+\$F\$13*E92)*(\$B\$20*F92+\$C\$20*G92)*\$C\$41*\$B\$27*\$B\$34*\$B\$7)/((((\$B\$13*A92+\$C\$13*B92+\$D\$13*C92+\$E\$13*D92+\$F\$13*E92)*(\$B\$20*F92+\$C\$20*G92)*\$C\$41*\$B\$27*\$B\$34*\$B\$7))))))$			
			0,294521727
			0
			0,483799326
			0
0,95	70,5	0,000154279	0,089355407
3,58	91	0,00072968	0,829584669
1,98	76,2	0,085244439	0
1,24	70,5	0,623544389	0
1,76	74	0,010540738	0,304759933
-2,57	69	0,044061019	0,930887914
-2,73	63,7	0	0,932434431
77			
78			
79			
80			
81			
82			
83			
84			
85			
86			
87			
88			
89			
$\mu_{PIMC}^{(xi)}$			
Magreza	Normal	SobrePeso	Obeso
0,0002	0,0002	0,7619	0,9802
0,0195	0,4868	0,0818	0,0065
0,0007	0,0047	0,9869	0,5461
0,0000	0,0000	0,0000	0,0019
0,0002	0,0002	0,7895	0,9692
0,0027	0,0513	0,6065	0,1531
0,0000	0,0000	0,0731	0,4020
0,0003	0,0010	0,9595	0,8096
0,0015	0,0198	0,8161	0,2893
0,0005	0,0026	0,9999	0,6519
0,7577	0,1458	0,0000	0,0000

Continua...

F92 $=1-1/(1+EXP(-\$J\$26*(B76-\$J\$28)))$			
	E	F	G
73			
74	P(ElevadoGrave/Pim c=Fuzzy^PCA=Fuzzy^AFS=Crisp^HERE=Crisp^PPA=Crisp)		
75	0,761017588		
76	0,001795164		
77	0,171091377		
78	0,516197272		
79	0,000511019		
80	0,910490314		
81	0,169685651		
82	0,914755561		
83	0,376455611		
84	0,68469933		
85	0,025051067		
86	0,067565569		
87			
88			
89			$\mu_{PCA}^{(xi)}$
90	ObesoGrave	Adequada	Alterada
91	0,7350	0,0000	1,0000
92	0,0022	0,9427	0,0573
93	0,2423	0,4134	0,5866
94	1,0000	0,0000	1,0000
95	0,7109	0,7311	0,2689
96	0,0411	0,0052	0,9948
97	0,9913	0,0000	1,0000
98	0,4850	0,0003	0,9997
99	0,0928	0,0052	0,9948
100	0,3274	0,0009	0,9991
101	0,0000	0,0110	0,9890
102	0,0000	0,1359	0,8641

ANEXO A – Tabelas com dados probabilísticos para formação da Base de Conhecimento da Rede Bayesiana Clássica

a) *Conditional Probabilities Table: P(PIMC|RiscoMetabolico)*

RiscoMetabolico	Magreza	Normal	SobrePeso	Obeso	ObesoGr...
Baixo	20,5	60	18	1	0,5
Moderado	6	20	27	42	5
Elevado Grave	3	4.17	8.33	25	59.5

b) *Conditional Probabilities Table: P(Hereditariedade|RiscoMetabolico)*

RiscoMetabolico	Nenhum	Pai ou Mae	Ambos
Baixo	80	14.29	5.71
Moderado	10	60	30
Elevado Grave	3	30	67

c) *Conditional Probabilities Table: P(AFS|RiscoMetabolico)*

Netica - [AtividadeFisicaSemanal Table (in net RB_EstadoNutricional_INGENUA_2)]

File Edit Table Window Help

Node: **AtividadeFisicaSemanal** Apply Okay

Chance % Probability Reset Close

RiscoMetabolico	Adequada	Inadequada	Sedentaris...
Baixo	94.28	2.86	2.86
Moderado	0	91.18	8.82
Elevado Grave	1	20	79

d) *Conditional Probabilities Table: P(PPA|RiscoMetabolico)*

Netica - [PPA Table (in net RB_EstadoNutricional_INGENUA_2)]

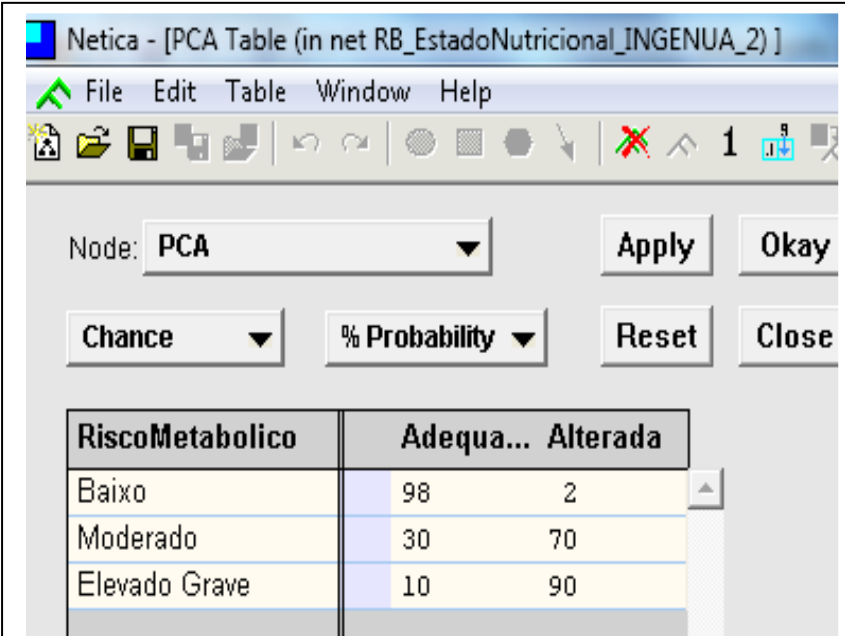
File Edit Table Window Help

Node: **PPA** Apply Okay

Chance % Probability Reset Close

RiscoMetabolico	Normal	Pre Hipertensao	Hipertensao
Baixo	94.29	5.71	0
Moderado	73.53	17.65	8.82
Elevado Grave	66.67	12.5	20.83

e) *Conditional Probabilities Table: P(PCARiscoMetabolico)*



Netica - [PCA Table (in net RB_EstadoNutricional_INGENUA_2)]


File Edit Table Window Help

Node: **PCA** Apply Okay

Chance ▾ % Probability ▾ Reset Close

RiscoMetabolico	Adequa... Alterada	
Baixo	98	2
Moderado	30	70
Elevado Grave	10	90

f) *Tabela das Probabilidades a priori: P(RiscoMetabolico)*



Netica - [RiscoMetabolico Table (in net RB_EstadoNutricional_INGENUA_2)]

File Edit Table Window Help

Node: **RiscoMetabolico** Apply Okay

Chance ▾ % Probability ▾ Reset Close

	Baixo	Moderado	Elevado Grave
	35	34	31

ANEXO B – Base de dados reais – levantamento e diagnóstico realizado pelo especialista médico
Conjunto de dados 1

	A	B	C	D	E	F	G	H	I	J	K	L	M	N
1	N	nasc	idade anos	genero	PA	PAP	Pto cortePre	ptocorteH	CA	pto de corte	CAP	AF (hsm)	AFP	peso
2	1	120700	10	F	110/70	N	118/76	120/80	84	69,6	AL	1	S	55,8
3	2	171199	11	M	110/60	N	117/76	121/81	54,4	72,4	AD	2	I	36,5
4	3	11004	7	F	110/70	N	111/72	115/76	60,7	62	AD	5	A	29,8
5	4	130800	11	F	140/80	A	119/76	123/80	129	71,8	AL	2	I	105,5
6	5	40406	5	M	100/70	N	115/70	116/74	58	58	AD	3	A	26,2
7	6	111199	11	F	110/60	N	120/77	124/81	70,5	71,8	AD	0	S	52
8	7	140800	10	M	110/80	N	119/78	123/82	91	70,1	AL	2	I	68
9	8	170701	10	F	110/70	N	118/76	122/80	76,2	69,6	AL	3	A	53,1
10	9	100203	8	F	100/70	N	114/74	118/78	70,5	64,7	AL	6	A	42,7
11	10	200102	9	F	100/70	N	116/75	120/79	74	67,3	AL	0	S	47,2
12	11	210102	10	M	110/70	N	112/73	116/78	69	70,1	AD	2	I	22,1
13	12	30996	14	F	130/75	A	121/77	125/81	63,7	77	AD	2	I	33,7

Continua...

	O	P	Q	R	S	T	U	V	W	X	Y	Z	AA
1	est	IMC	score-z	percentil	>P85SP	≤P97SP	>P97 O	≤P99 O	>99 og	Classe	HERE	D_Met	R_Cl
2	1,49	25,1	2,34	99,0				99,0		o	0	mod_elevado	elev_grave
3	1,45	17,4	-0,04	48,2						n	0	baixo	baixo
4	1,26	18,8	1,62	94,7		94,7				sp	2	moderado	mod_elevado
5	1,52	45,7	5,33	99,9					99,9	og	1	elevado	grave
6	1,18	18,8	2,30	98,9				98,9		o	0	elevado	grave
7	1,6	20,3	0,95	82,8	82,8					n	2	baixo	moderado
8	1,5	30,2	3,58	99,9					99,9	og	0	grave	grave
9	1,53	22,7	1,98	97,0		97,0				sp	2	moderado	mod_elevado
10	1,51	18,7	1,24	89,2	89,2					sp	1	moderado	mod_elevado
11	1,5	21,0	1,76	96,0		96,0				sp	0	moderado	elevado
12	1,29	13,3	-2,57	0,5						m	0	baixa	moderada
13	1,51	14,8	-2,73	0,6						m	0	baixa	moderado

Continua...

Caso 1: diagnóstico de risco metabólico é moderado a elevado considerando hereditariedade zero, e PA normal; no entanto sua CA é alterada, sedentário, e seu percentil de IMC está alto, praticamente no P de obeso grave; então meu diagnóstico Clínico é de risco metabólico grave.

Caso 2: diagnóstico de risco metabólico baixo, uma vez que todos os parâmetros não apresentam risco, exceto pela atividade física que precisaria ser aumentada. O diagnóstico clínico é de risco baixo.

Caso 3: risco metabólico moderado, considerando o IMC e a atividade física; no entanto se considerarmos a hereditariedade, o IMC próximo da obesidade e a PA próxima ao Pré-hipertensão classificaria como moderado a elevado, como diagnóstico clínico.

Caso 4: a avaliação nutricional informa ser um obeso grave, com diagnóstico metabólico elevado à grave, no entanto quando se observa que ainda há alteração da CA, hereditariedade e atividade física inadequada, se classifica como clinicamente grave.

Caso 5: risco metabólico elevado considerando o IMC, PA norma e hereditariedade zero, com AF. No entanto ao se observar os pontos de corte vemos que, o IMC está praticamente no ponto de corte para OG e a PA está próximo ao Pré-hipertensivo e a circunferência sobrepõe o ponto de corte para alterada.

Caso 6: Ainda que o risco metabólico seja baixo em função dos valores antropométricos e da hereditariedade e PA, vemos que a CA está próxima ao ponto de corte de Alterada e o IMC está próximo do SP, em uma paciente sedentária, considero clinicamente que essa criança tem um risco clínico moderado.

Caso 7: o risco metabólico é grave dado o seu IMC, que é reforçado pela alteração da CA, a vigência de uma pré hipertensão com a AF inadequada, sendo que mesmo que seu IMC seja de obeso ainda assim ela permanece com o risco clínico de grave.

Caso 8: O risco metabólico é de risco moderado, dada a CA alterada e um IMC de SP, no entanto se consideramos o ponto de corte do IMC, vemos que está próximo a obesidade, agravada pela CA alterada e a hereditariedade, o diagnóstico clínico ficaria em moderado para elevado.

Caso 9: se consideramos o IMC, ele seria de risco metabólico moderado, no entanto como sua CA esta alterada, sua PA diastólica esta próxima ao ponto de corte de pré-hipertensão, hereditariedade positiva daria para classificá-lo como mod_elevado.

Caso 10: Pela avaliação antropométrica ele seria considerado moderado, no entanto se considerarmos a CA, seu IMC próximo a obeso e sedentarismo, eu o classificaria em elevado.

Caso 11: Ainda que a antropometria o indique como baixo risco em função da magreza, considere-se que, que Padiastolica próxima ao pré-hipertensão, CA próxima ao ponto de corte para alterada; AF inadequada; classificação clínica de moderado.

Caso 12: Ainda que o IMC leve ao diagnóstico clínico de baixo risco há presença de Hipertensão, levando o risco clínico para moderado.

ANEXO C – Base de dados reais – levantamento e diagnóstico realizado pelo especialista médico
Conjunto de dados 2

	A	B	C	D	E	F	G	H	I	J	K	L	M	N
1	N	nasc	Idade anos	genero	PA	PAP	Pto cortePre	ptocorteH	CA	pto de corte	CAP	AF (hsm)	AFP	peso
2	1	61095	16	M	120/70	N	130/80	134/85	77	83,2	AD	5	A	68
3	2	250500	11	M	110/60	N	119/77	123/82	104	72,4	AL	2	I	70,1
4	3	20901	10	F	110/70	N	116/75	120/79	71	69,6	AL	3	A	36,4
5	4	270197	13	M	110/70	N	125/79	129/83	85	76,9	AL	4	A	77
6	5	170300	10	M	110/75	N	119/77	122/81	79	70,1	AL	4	A	56,6
7	6	30700	10	M	120/80	A	119/77	122/81	95	70,1	AL	3	A	64,8
8	7	130997	12	F	115/70	N	120/77	124/81	76,5	73,8	AL	3	A	56,4
9	8	41298	12	M	120/85	A	123/78	127/83	110	74,7	AL	2	I	82,8
10	9	11204	6	F	110/60	N	111/72	115/76	59,2	59,5	AD	4	A	27,1

Continua...

	O	P	Q	R	S	T	U	V	W	X	Y	Z	AA
1	est	IMC	score-z	percentil	>P85SP	≤P97SP	>P97 O	≤P99 O	>99 og	Classe	HERE	D_Met	R_Cl
2	1,75	22,2	0,59	72,1						n	0	baixo	baixo
3	1,51	30,7	3,19	99,9					99,9	og	2	grave	grave
4	1,39	18,8	0,88	81,3	81,3					n	0	baixo	moderado
5	1,71	26,3	2,2	98,8				98,8		o	0	elevado	grave
6	1,47	26,2	2,92	99				99		o	2	elevado	grave
7	1,52	28,0	3,24	99,9					99,9	og	1	grave	grave
8	1,55	23,5	1,52	93,5	93,5					sp	0	moderado	elevado
9	1,68	29,3	2,75	99				99		o	1	elevado	grave
10	1,24	17,6	1	87,8	87,8					sp	0	moderado	elevado

Continua...

Caso 1: Diagnostico de Risco metabólico e RC baixo.

Caso 2: Diagnostico de risco metabólico grave, com reforço pela CA alterada, atividade física inadequada e presença de hereditariedade dupla: RC grave.

Caso 3: Ainda que o diagnóstico de avaliação nutricional seja de eutrofia e paciente faça atividade física, PA normal, sem história familiar, observa-se que sua CA esta alterada e o IMC próximo ao SP, o RC se opõe ao Diagnostico de Risco Metabólico baixo e passa para Risco metabólico moderado.

Caso 4: Apresenta PA normal; CA alterada; com atividade física adequada, mas IMC próximo a obeso grave, então RC para GRAVE.

Caso 5: PA normal e AF OK; no entanto CA alterada, sugerindo risco cardíaco; IMC obeso, próximo a Obeso grave com hereditariedade, leva ao RC de GRAVE.

Caso 6: é grave risco metabólico e com RC também de grave, uma vez que todos os parâmetros estão alterados.

Caso 7: com PA normal, CA alterada, AF adequada; hereditariedade 0; e IMC mais próximo do obeso então RC fica e elevado.

Caso 8: PA alterada, CA alterada, AF inadequada, hereditariedade positiva para um membro e IMC encostado no Obeso Grave; Então RC GRAVE.

Caso 9: PA normal, CA sobrepondo a Alterada; AF adequada, IMC para SP e hereditariedade zero, Mas em função da CA limítrofe, alterada e Sobre peso, o RC nos leva a ter cautela, uma vez que a CA alterada tem relação com HDL, refletindo risco cardíaco para ser elevado.

Equipe de especialistas:

- Profa. Mônica Lisboa Chang Wayhs - MD/Msc/PhD, Serviço de Nutrologia do Departamento de Pediatria da UFSC
- Profa. Maria Marlene de Souza Pires - MD/PhD, Serviço de Nutrologia do Departamento de Pediatria da UFSC
- Profa. Marileise dos Santos Obelar - MD/Msc, Departamento Materno-Infantil da Unisul
- Ana Paula Aragão – MD, Pediatra Nutróloga