

PROPAGAÇÃO DE INCERTEZAS EM REDES BAYESIANAS ATRAVÉS DO
MÉTODO DE MONTE CARLO E LÓGICA FUZZY PARA APLICAÇÃO EM
ANÁLISES PROBABILÍSTICAS DE SEGURANÇA DE CENTRAIS NUCLEARES

Lilian Braga Estevão

Tese de Doutorado apresentada ao Programa de Pós-graduação em Engenharia Nuclear, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Doutor em Engenharia Nuclear.

Orientador: Paulo Fernando Ferreira Frutuoso e
Melo

Rio de Janeiro
Abril de 2019

PROPAGAÇÃO DE INCERTEZAS EM REDES BAYESIANAS ATRAVÉS DO
MÉTODO DE MONTE CARLO E LÓGICA FUZZY PARA APLICAÇÃO EM
ANÁLISES PROBABILÍSTICAS DE SEGURANÇA DE CENTRAIS NUCLEARES

Lilian Braga Estevão

TESE SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO LUIZ
COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA (COPPE) DA
UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS
REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR EM
CIÊNCIAS EM ENGENHARIA NUCLEAR.

Examinada por:

Prof. Paulo Fernando Ferreira Frutuoso e Melo, D.Sc.

Prof(a). Andressa dos Santos Nicolau, D.Sc.

Prof. Celso Marcelo Franklin Lapa, D.Sc.

Prof. Carlos André Vaz Junior, D.Sc.

Prof. Gilson Brito Alves Lima, D.Sc.

RIO DE JANEIRO, RJ - BRASIL

ABRIL DE 2019

Estevão, Lilian Braga

Propagação de Incertezas em Redes Bayesianas através do Método de Monte Carlo e Lógica Fuzzy para Aplicação em Análises Probabilísticas de Segurança de Centrais Nucleares/ Lilian Braga Estevão. – Rio de Janeiro: UFRJ/COPPE, 2019.

XIII, 82 p.: il.; 29,7 cm.

Orientador: Paulo Fernando Ferreira Frutuoso e
Melo

Tese (doutorado) – UFRJ/ COPPE/ Programa de Engenharia Nuclear, 2019.

Referências Bibliográficas: p. 57-62.

1. Propagação de Incertezas. 2.Redes Bayesianas. 3. Lógica Fuzzy. 4. Análise de Segurança. I. Melo, Paulo Fernando Ferreira Frutuoso e. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Nuclear. III. Título.

“A principal vantagem de raciocínio probabilístico sobre raciocínio lógico é o fato de que agentes podem tomar decisões racionais mesmo quando não existe informação suficiente para se provar que uma ação funcionará.”

Russel

AGRADECIMENTOS

A Deus por estar sempre presente, me iluminando e abençoando.

Aos meus pais, Denise e Bernardino, pela confiança, incentivo, paciência e muito amor oferecido a mim.

A meu esposo, Maxwell, por estar sempre presente. Por todo companheirismo, amor e compreensão. Por abrir mão de tantas coisas, para que eu pudesse estudar!

À amiga Dillyane, que esteve sempre ao meu lado a cada dificuldade e sempre com pensamentos positivos. Fazendo-me acreditar que tudo daria certo.

Aos meus sobrinhos, Jorge, Beatriz e Anna, por me darem tanto orgulho, carinho e amor.

Aos meus lindos amigos Márcio, Gabriela, Felipe, Gabriel, Anne, Patrick e Hebert, por estarem sempre por perto, incentivando e alegrando os meus dias.

Ao meu orientador, Paulo Fernando Ferreira Frutuoso e Melo, por todo ensinamento passado no decorrer deste trabalho.

Aos queridos Reginaldo, Lili, Washington e Marcos por todo carinho.

Aos meus bebês, Taylor, Sininho, Hazel, Molly e Lilly, por toda atenção e carinho que dedicam a mim. Um amor incondicional!!!!

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.).

PROPAGAÇÃO DE INCERTEZAS EM REDES BAYESIANAS ATRAVÉS DO
MÉTODO DE MONTE CARLO E LÓGICA FUZZY PARA APLICAÇÃO EM
ANÁLISES PROBABILÍSTICAS DE SEGURANÇA DE CENTRAIS NUCLEARES

Lilian Braga Estevão

Abril / 2019

Orientador: Paulo Fernando Ferreira Frutuoso e Melo

Programa: Engenharia Nuclear

Este trabalho investiga a propagação de incertezas em Redes Bayesianas, para o Sistema de Remoção de Calor da Contenção (CHRS), com a utilização de uma modelagem híbrida, contendo o Método de Monte Carlo e a lógica fuzzy, para a propagação dos eventos utilizando a lógica booleana e o erro de ação humana, respectivamente. O CHRS possui a função de resfriar o reservatório de água que está sendo recirculado através do Sistema de Recirculação do Spray da Contenção (CSRS). O CSRS é iniciado automaticamente após um acidente de perda de refrigerante (LOCA) e junto com o CHRS encontra maneiras de remover o calor do reservatório. Os resultados obtidos através da modelagem foram satisfatórios, evidenciando a possibilidade de estimar incertezas, mesmo com escassez de dados.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.).

PROPAGATION OF UNCERTAINTIES IN BAYESIAN NETWORKS THROUGH
THE MONTE CARLO AND FUZZY LOGIC METHOD FOR APPLICATION IN
PROBABILITY ANALYSIS OF NUCLEAR CENTRAL SECURITY

Lilian Braga Estevão

April / 2019

Advisor: Paulo Fernando Ferreira Frutuoso e Melo

Department: Nuclear Engineering

This work investigates the propagation of uncertainties in Bayesian Networks, for the Containment Heat Removal System (CHRS), using a hybrid modeling, containing the Monte Carlo Method and fuzzy logic, for the propagation of events using Boolean logic and the human error of action, respectively. CHRS has the function of cooling the water tank being recirculated through the Containment Spray Recirculation System (CSRS). CSRS starts automatically after a refrigerant loss accident (LOCA) and along with CHRS finds ways to remove heat from the reservoir. The results obtained through the modeling were satisfactory, evidencing the possibility of estimating uncertainties, even with data shortages.

SUMÁRIO

1	INTRODUÇÃO.....	1
1.1	MOTIVAÇÃO, ORIGINALIDADE E RELEVÂNCIA.....	1
1.2	JUSTIFICATIVA.....	2
1.3	OBJETIVO.....	2
1.4	METODOLOGIA.....	3
1.5	ORGANIZAÇÃO DO TRABALHO.....	3
2	REVISÃO BIBLIOGRÁFICA.....	4
3	FUNDAMENTOS TEÓRICOS.....	7
3.1	ANÁLISE DE INCERTEZAS.....	7
3.1.1	INCERTEZAS NO MODELO.....	8
3.2	TEOREMA DE BAYES.....	9
3.3	TEORIA DOS GRAFOS.....	10
3.4	REDES BAYESIANAS.....	11
3.5	VARIÁVEIS ALEATÓRIAS.....	13
3.5.1	DISTRIBUIÇÕES DE PROBABILIDADES DE UMA VARIÁVEL ALEATÓRIA CONTÍNUA.....	13
3.5.1.1	DISTRIBUIÇÃO UNIFORME.....	14
3.5.1.2	DISTRIBUIÇÃO DE WEIBULL.....	14
3.5.1.3	DISTRIBUIÇÃO EXPONENCIAL.....	15
3.5.1.4	DISTRIBUIÇÃO DE NORMAL.....	16
3.5.1.5	DISTRIBUIÇÃO DE LOGNORMAL.....	17
3.5.2	MÉDIA E VARIÂNCIA DE UMA VARIÁVEL ALEATÓRIA CONTÍNUA.....	18

3.6	MÉTODO DE MOMENTOS.....	19
3.7	MÉTODO DE MONTE CARLO.....	20
3.7.1	SIMULAÇÃO DE MONTE CARLO CLÁSSICA.....	23
3.7.2	SIMULAÇÃO DE MONTE CARLO BAYES.....	24
3.7.2.1	AMOSTRAGEM POR HIPERCUBO LATINO.....	24
3.7.2.2	AMOSTRAGEM POR IMPORTÂNCIA.....	25
3.7.3	MÉTODO DE SIMULAÇÃO BOOTSTRAP.....	27
3.8	MÉTODO DE SUPERFÍCIE DE RESPOSTA.....	29
3.9	LÓGICA <i>FUZZY</i>	30
3.10	COMPARAÇÃO ENTRE OS MÉTODOS.....	36
3.11	ÁRVORE DE FALHAS.....	38
3.11.1	SIMBOLOGIA DA ÁRVORE DE FALHAS.....	23
4	PROBLEMA INVESTIGADO	42
5	RESULTADOS	48
5.1	MODELAGEM PARA O MÉTODO DE MONTE CARLO.....	49
5.2	MODELAGEM POR LÓGICA <i>FUZZY</i>	50
6	CONCLUSÃO E RECOMENDAÇÕES.....	55
	REFERÊNCIAS BIBLIOGRÁFICAS.....	57

ÍNDICE DE FIGURAS

	PÁGINA
Figura 3.1 – Grafo direcionado	10
Figura 3.2 – Grafo não direcionado	10
Figura 3.3 – Grafo acíclico direcionado	11
Figura 3.4 – Rede bayesiana elaborada no netica	12
Figura 3.5 – Parte qualitativa das redes bayesianas	12
Figura 3.6 – Função densidade de probabilidade contínua uniforme	14
Figura 3.7 – Função densidade de probabilidade de Weibull para valores selecionados de δ e β	15
Figura 3.8 - Função densidade de probabilidade de uma variável aleatória exponencial para valores selecionados de λ	16
Figura 3.9 – Curva normal típica	17
Figura 3.10 – Função densidade lognormal	18
Figura 3.11 – Fluxograma do método de simulação de Monte Carlo	21
Figura 3.12 – Ilustração do método de bootstrap não paramétrico	28
Figura 3.13 – Ilustração do método de bootstrap paramétrico	29
Figura 3.14– Estrutura do Sistema da lógica <i>fuzzy</i>	32
Figura 4.1 –Árvore de falhas, modelada no SAPHIRE, do CHRS	44
Figura 4.2 – Continuação da árvore de falhas do CHRS	45
Figura 4.3 – Redes bayesianas, mapeada da árvore de falhas do CHRS	46
Figura 4.4 – Redes Bayesianas, mapeada da árvore de falhas do CHRS	47

Figura 5.1 – Fluxograma da modelagem híbrida realizada	49
Figura 5.2 – Função de pertinência	51
Figura 5.3– Modelagem híbrida para a propagação de incertezas	54

ÍNDICE DE TABELAS

	PÁGINA
Tabela 3.1 – Comparação entre os métodos de propagação de incertezas	37
Tabela 3.2 – Diferentes eventos primários	39
Tabela 3.3 – Evento intermediário e evento transferência	40
Tabela 3.4 – Portões lógicos	41
Tabela 5.1 – Uma forma de estimar os limites, superior e inferior, para estimar a taxa de falha	50
Tabela 5.2 – Resultado da fuzzyficação	52
Tabela 5.3 – Médias encontradas após as simulações	53

LISTA DE SIGLAS

AAS	Amostragem Aleatória Simples
AF	Árvore de Falhas
AHL	Amostragem por Hipercubo Latino
AI	Amostragem por Importância
APR	Avaliação Probabilística de Risco
APS	Análise Probabilística de Segurança
CHRS	Sistema de Remoção de Calor da Contenção
CSRS	Sistema de Refrigeração do Spray da Contenção
DDP	Distribuição Discreta de Probabilidade
FDA	Função Distribuição Acumulada
FDP	Função Densidade de Probabilidade
FIM	Medida de Importância <i>Fuzzy</i>
FUIM	Medida de Importância de Incerteza <i>Fuzzy</i>
FORM	Método de Confiabilidade de Primeira Ordem
GAD	Grafo Acíclico Direcionado
GNA	Gerador de Números Aleatórios
HEP	Probabilidade de Erro Humano
HRA	Análise de Confiabilidade Humana
LF	Lógica <i>Fuzzy</i>
LOCA	Acidente de Perda de Refrigerante
LHS	Amostragem por Hipercubo Latino
MCMC	Monte Carlo Cadeia de Markov
MCT	Monte Carlo Total
MMC	Método de Monte Carlo
MSR	Método de Superfície de Resposta
RB	Redes Bayesianas
SORM	Método de Confiabilidade de Segunda Ordem
SRS	Amostragem Aleatória Simples
TA	Técnica de Amostragem
TRV	Técnica de Redução de Variância
VA	Variável Aleatória

1 INTRODUÇÃO

1.1 MOTIVAÇÃO, ORIGINALIDADE E RELEVÂNCIA

A comunidade científica está cada vez mais contribuindo para o desenvolvimento de técnicas que auxiliem no cálculo da indisponibilidade de sistemas de segurança de centrais nucleares. Com isto, este trabalho tem por motivação avaliar os métodos que possam contribuir para a propagação de incertezas, e indicar, dentre os métodos, qual a melhor opção.

Antigamente os computadores tinham limitações, que dificultavam a utilização do método de Monte Carlo. Os poucos recursos computacionais disponíveis, não permitiam que o analista obtivesse uma precisão em seus resultados. Com o avanço tecnológico, estas limitações estão deixando de ser um problema.

Messetti e Queiroz (2002) garantem que o método de Monte Carlo é eficiente, de fácil aplicação e deve ser utilizado, uma vez que se observe que não haja a possibilidade de se obter resultados analiticamente. Para as autoras, o método de Monte Carlo: “é um método numérico auxiliar, para resolver problemas matemáticos mediante simulação de variáveis aleatórias, em que não é possível obter solução de forma analítica, ou mesmo usar solução numérica se torna inviável”.

O sistema a ser utilizado, é o Sistema de Remoção de Calor da Contenção (CHRS), cujo objetivo é resfriar a água do poço da contenção, recirculando através do *Containment Spray Recirculation System* (CSRS). Este último é iniciado automaticamente após um acidente de perda de refrigerante (LOCA) e em conjunto com o CHRS disponibiliza meios para remover o calor da água do poço da contenção.

Os métodos de simulação possuem vantagens, tais como: permitem simular períodos longos em pouco tempo (dependendo do sistema), pode-se entender melhor a interação das variáveis do sistema e a possibilidade de tratar eventos que não poderiam ser tratados analiticamente, como já foi dito.

As principais desvantagens na utilização destes métodos encontram-se na dificuldade em modelar o problema proposto. O tempo computacional já foi algo de muita preocupação para os analistas. Isto está deixando, aos poucos de ser um problema, devido

à evolução computacional e o desenvolvimento de algoritmos que têm a função de reduzir o tempo de execução.

O tema é considerado original pois, mediante a toda pesquisa realizada no decorrer do doutorado, foi percebido uma lacuna na literatura. Esta lacuna propiciou a originalidade do trabalho em questão.

A relevância deste estudo tem como base o fato de que, em uma usina nuclear, a análise probabilística de segurança é de suma importância, assim, será estudado como as técnicas de propagação de incertezas podem trabalhar em conjunto com as redes bayesianas a fim de obter as indisponibilidades possíveis de sistema de interesse.

1.2 JUSTIFICATIVA

Após um extenso levantamento de artigos científicos, pôde-se observar uma lacuna na literatura, e esta deu origem ao trabalho de tese. Assim, este estudo se justifica pela necessidade de se compreender o processo de propagar as incertezas, quando não se conhece a probabilidade de falha dos nós raízes das Redes Bayesianas (RB) com precisão. Esta propagação pode ser feita através da opinião de especialistas e pode ser tratada a ação humana com o uso da lógica fuzzy. As redes bayesianas são ferramentas muito úteis, principalmente quando se trata da possibilidade de modelar eventos dependentes de forma organizada e objetiva.

1.3 OBJETIVO

O objetivo desta tese é estudar a propagação de incertezas em redes bayesianas desenvolvidas no âmbito de análises probabilísticas de segurança de centrais nucleares (para o cálculo de indisponibilidades de sistemas de segurança da central). Esta propagação conta com uma modelagem híbrida (monte carlo – lógica fuzzy), que propicia a resolução de problemas, onde dados são escassos.

1.4 METODOLOGIA

Para o cálculo da rede bayesiana do sistema de remoção de calor da contenção foi utilizada uma modelagem híbrida, contendo o método de Monte Carlo e lógica *fuzzy*. Essa modelagem híbrida permite que se propaguem incertezas, mesmo com escassez de dados. Uma linguagem de programação foi construída, a fim de se obter inúmeros valores possíveis. Através destes valores, construiu-se um histograma, obtendo-se a média dos resultados. Sendo assim, a propagação de incertezas foi realizada.

1.5 ORGANIZAÇÃO DO TRABALHO

O Capítulo 2 se refere à pesquisa bibliográfica que abrange os assuntos de interesse deste trabalho. O Capítulo 3 será reservado aos fundamentos teóricos, onde serão abordados os conceitos básicos necessários para um bom entendimento do trabalho e serão discutidos os métodos de propagação de incertezas existentes na literatura. Será feita uma comparação destes métodos e destacar-se-á o de melhor aplicabilidade para o problema proposto. O Capítulo 4 ilustra qual sistema será utilizado no trabalho e o motivo desta escolha. O Capítulo 5 apresenta os resultados provenientes da modelagem híbrida utilizada e, por fim, o Capítulo 6 é destinado à conclusão do trabalho de tese. Ao final, seguem as referências bibliográficas: todas as referências consultadas e mencionadas no decorrer deste trabalho estão listadas neste tópico. Também compõe o corpo deste trabalho um anexo, do qual constam informações para uma melhor compreensão acerca dos assuntos abordados.

2 REVISÃO BIBLIOGRÁFICA

Guimarães e Ebecken (1999) descrevem uma nova aproximação e um novo sistema computacional, FuzzyFTA, para analisar a confiabilidade, fazendo uso da árvore de falhas e da lógica *fuzzy*. As confiabilidades de falhas dos componentes são consideradas como conjuntos *fuzzy* triangular. Utilizaram o método α -cut, para avaliar a probabilidade de falha do evento topo na árvore de falha. Os autores introduziram duas importantes medidas de importância: medida de importância *fuzzy* (FIM) e medida de importância de incerteza *fuzzy* (FUIM).

Guimarães e Lapa (2004) propõem um conceito de um sistema de lógica *fuzzy* puro, onde a base de regras *fuzzy* consiste em uma coleção de regras *fuzzy* IF-THEN. A utilização da regra *fuzzy* IF-THEN se explica devido ao mapeamento do conjunto *fuzzy* no universo de entrada do discurso, para o conjunto *fuzzy* no universo de saída do discurso, baseado nos princípios lógicos *fuzzy*. Observou-se que os resultados demonstram o potencial da inferência *fuzzy* para gerar uma base de conhecimento que correlaciona operações de ocorrências e desempenho da planta.

Langseth e Portinale (2005) discutem as vantagens das redes bayesianas em comparação com as técnicas já conhecidas, como por exemplo, árvores de falhas. Os autores mostram como construir uma rede bayesiana através da opinião de especialista. Afirmam que, para a construção de uma RB, é necessário que se tenha valores de entradas de domínio dos especialistas e dados estatísticos. Para construção de um modelo de RB, tornam-se necessários alguns passos. Passo 0: decidir o que modelar. Selecionar o limite a ser incluído neste modelo. Passo 1: definir as variáveis. Selecionar as variáveis importantes neste modelo. Passo 2: parte qualitativa. Será definida a estrutura gráfica que conecta as variáveis. Passo 3: parte quantitativa. Para definir a parte quantitativa, devem-se selecionar famílias de distribuição para todas as variáveis e fixar parâmetros para especificar as distribuições.

Simões Filho (2006) desenvolve uma análise de incertezas no evento topo de árvores de falhas, advindas das incertezas da indisponibilidade dos subsistemas/equipamentos/ componentes (eventos básicos). O autor propõe uma metodologia alternativa, mais rápida, mais eficiente e mais fácil de aplicar. Ele garante

que sua nova metodologia pode ser programada como um pós-processador, independentes dos *softwares* de árvores de falhas existentes. A grande vantagem do uso desta metodologia é a versatilidade que ela oferece.

Modarres (2006) afirma que em Avaliação Probabilística de Risco (APR), as incertezas são primariamente mostradas na forma de distribuições de probabilidade. O autor expõe cinco passos existentes na análise de incertezas: 1) Identificar modelos e parâmetros que são incertos e o método de estimação de incerteza a ser utilizado para cada; 2) Descreve o escopo da APR e os elementos de contribuição e significância que não são modelados ou considerados; 3) Estimar e atribuir distribuições de probabilidades que descrevem modelo e parâmetros de incerteza na APR; 4) Propagar incertezas associadas com os parâmetros e modelos das barreiras de perigo, para encontrar a incerteza associada com o valor de risco; 5) Apresentar a incerteza associada com riscos e contribuições para o risco numa maneira visualmente fácil de entender.

Vieira (2006) utiliza a amostragem por importância na probabilidade do número de acertos em alvos, com Monte Carlo. O autor utiliza este método de simulação para demonstrar o quão eficiente é a amostragem por importância, e que com ela é possível utilizar métodos de simulação, gastando menos tempo computacional. Porém, a implantação deste tipo de técnica não é simples. É necessário que o analista tenha domínio da técnica, pois ela pode conduzir, se não utilizada adequadamente, a resultados errôneos.

Zonouz e Miremadi (2006) relacionam a simulação de Monte Carlo tradicional com a Simulação de Monte Carlo *Fuzzy*. Garantem que a simulação de Monte Carlo *Fuzzy* pode estimar o tempo para falhar do sistema que contém componentes que falham gradualmente, como por exemplo, degradação. Fazendo a comparação entre estas duas técnicas, percebe-se que a ordem do tempo da abordagem da simulação de Monte Carlo Fuzzy é igual à multiplicação da ordem temporal da simulação de Monte Carlo tradicional por um número fuzzy que representa o comprimento da matriz. Os autores utilizam a simulação de Monte Carlo Fuzzy para calcular o tempo até falhar de um sistema.

Segundo Jones et al. (2010), a RB é uma fórmula matemática simples capaz de calcular probabilidades de eventos aleatórios. Neste artigo foi destacada a capacidade da RB de lidar com probabilidades subjetivas através da opinião de especialistas. Dentre as aplicações da RB, os autores realçam a manutenção preventiva, que é uma atividade com o propósito de reduzir a ocorrência de falhas no sistema. Existe também a manutenção corretiva, que é realizada após ocorrer falha de algum ponto do sistema.

Barrio et al. (2011) propõem ideias sobre o Método de Séries de Taylor Estendido, para propagar as incertezas em condições iniciais. É fornecido um estimador de erro de qualidade das aproximações de multivariável, permitindo selecionar o tamanho da caixa de valor inicial de incerteza. Os cálculos foram realizados utilizando o software livre TIDES, desenvolvido pelos autores.

Guimarães et al. (2011) utilizaram lógica fuzzy para modelar incertezas no reator nuclear avançado da Westinghouse (AP1000), logo após um incidente ter sido detectado. A aproximação fuzzy foi empregada após um acidente de perda de refrigerante (LOCA).

Rochman et al. (2013) expõem um método de Monte Carlo para propagação de incertezas chamado de o rápido método de Monte Carlo Total (MCT). Os autores comparam este método rápido ao original, destacando sua eficiência pelo menor tempo computacional. Ao final, os autores introduzem outro método para fazer parte das comparações: método GRS rápido. Gráficos são utilizados para exemplificar cada método citado. Foi concluído que os métodos rápidos são, de fato, mais eficientes.

Jahani et. al. (2014), modelaram os conhecimentos incompletos sobre os parâmetros de distribuição, utilizando números *fuzzy*. As variáveis básicas de entrada são consideradas as variáveis aleatórias *fuzzy* e a avaliação de confiabilidade é expressa em termos de números *fuzzy*.

Papaioannou et al. (2015) utilizaram o método de Monte Carlo e método de confiabilidade de primeira e segunda ordem (FORM/SORM), para superar a ineficiência do método de Monte Carlo em estimar pequenas probabilidades de falhas, os autores utilizam Simulação de Subconjunto. Este artigo fornece resultados teóricos como médias assintóticas e variâncias assim como a normalidade assintótica da estimativa de probabilidade. Os autores garantem que a eficiência e precisão da Simulação de Subconjunto dependem da capacidade de aplicação do algoritmo MCMC para estimar precisamente a probabilidade condicional com números mínimos de amostras.

Ribeiro et. al. (2016) apresentam um modelo de análise de confiabilidade humana (HRA) que permite a incorporação de recursos relacionados para facilitar as condições a fim de determinar a probabilidade de erro humano (HEP), usado em análise probabilística de segurança de plantas de processo.

3 FUNDAMENTOS TEÓRICOS

3.1 ANÁLISE DE INCERTEZAS

Segundo Modarres (2006), as incertezas surgem da falta de, ou insuficiente, conhecimento acerca dos eventos. O autor introduz a definição de conhecimento como sendo “...uma mistura de experiência, valores, informação contextual e uma percepção que fornece um quadro para avaliar e incorporar novas experiências e informações e a tomada de decisões racionais.”

Amendola (1986) destaca os efeitos que mais contribuem para as incertezas nos resultados. Seguem: aspectos gerais (processo de tomada de decisão mal definido e procedimentos implicitamente assumidos), áreas com falta de consenso (falhas de causa comum e fatores humanos), dados (uso de dados, limites dos componentes, grau de acoplamento nas taxas de falhas e fontes de dados) e modelagem (interpretação de documentação, suposições quando documentações não estão completas, definição e interpretação do evento topo, definição e interpretação dos limites dos sistemas, análise incompleta e tempo de intervenção do operador).

As incertezas são classificadas em dois tipos: aleatória e epistemológica. A primeira foi definida como aquela incerteza que resulta quando um experimento ou observação é repetido sob condições idênticas, mas com diferentes resultados. A segunda caracteriza o estado de conhecimento sobre a construção de um modelo, Modarres (2006).

Nas estimativas dos parâmetros dos modelos surgem incertezas devido à grande variedade de fontes. As incertezas surgem de erros de medição, que podem ser erros aleatórios e sistemáticos. É necessário fazer a distinção entre o erro e a incerteza. O erro é definido como a diferença entre o resultado de uma medição e o valor verdadeiro do mensurando (grandeza específica submetida à medição). Já a incerteza é uma estimativa que quantifica a confiabilidade do resultado de uma medição. A incerteza é calculada mesmo quando não se tem idéia dos valores em questão.

A confiabilidade é definida como a capacidade do componente, produto ou sistema apresentar a sua função requerida sob condições de estado na presença de incertezas, Jahani et al. (2014).

Conforme informado anteriormente, o erro se divide em aleatório, quando se repete a medição por diversas vezes e a cada vez se obtém um erro diferente. Esse tipo de erro está ligado às flutuações que se encontram em qualquer tipo de experimento. E o erro sistemático está presente na medição, porém se repetimos a medição inúmeras vezes, esse erro não será anulado, ele sempre irá se repetir da mesma maneira.

A maneira mais simples para representar a probabilidade como uma medida da incerteza é usar a média \bar{x} e variância s^2 de uma propriedade associada a um evento, processo ou fenômeno de interesse e qualquer incerteza epistemológica associada a estas estimativas. Em uma abordagem de estimativa clássica, somente os intervalos de confiança de \bar{x} e s^2 podem ser estimados, Modarres (2006).

Em geral, o problema de encontrar a distribuição de uma função de variáveis aleatórias é difícil, razão pela qual para na maioria das aplicações de confiabilidade e de avaliação do risco o problema é reduzido ao cálculo da média e da variância (ou desvio padrão) da função de muitas variáveis aleatórias, Modarres (2006).

3.1.1 INCERTEZAS DO MODELO

A incerteza no modelo ocorre devido à falta de perfeição dos modelos. Em modelos APR, como por exemplo, árvores de eventos e árvores de falhas, possuem maneiras alternativas para a construção de seu método.

Segundo Sastry (1999), as diferentes fontes de incertezas do modelo são divididas em: 1) Estrutura do modelo: a incerteza surge quando existem conjuntos alternativos para o desenvolvimento do modelo. Assim, quando ao final do desenvolvimento os modelos alternativos chegarem a conclusões similares, então se pode ter certeza de que a decisão é sólida diante das incertezas. Porém, se houver conclusões distintas, deverá ser feita uma avaliação mais detalhada do problema. 2) Detalhes do modelo: muitas vezes os modelos são simplificados para fins de rastreabilidade. Um exemplo disto é converter um modelo não linear complexo em um modelo linear simples para realizar os cálculos. 3) Extrapolação: Modelos que são validados por parte da entrada podem ser completamente inadequados para fazer previsões em outras regiões do espaço de interesse. Por exemplo, um modelo de dose de resposta com base em altas doses, os testes de curta duração em animais, podem envolver erros significativos quando aplicados a estudos em baixas doses

ou de longa duração de exposição humana. 4) Resolução do modelo: na aplicação de modelos lógicos e matemáticos, a seleção da grade temporal ou espacial ou tamanho da estrutura, frequentemente envolve incertezas. Por um lado, há uma troca entre o tempo de computação (quanto maior, mais custo) e precisão da previsão. Por outro lado, existe uma troca entre a resolução e a validade das equações que regem o modelo de tais escalas. 4) Limites do modelo: qualquer modelo pode ter fronteiras limitadas em termos de tempo e espaço. A seleção de um modelo limite pode ser um tipo de simplificação. Dentro do limite, o modelo pode ser uma representação precisa, mas outro fenômeno esquecido, não incluído no modelo, pode desempenhar um papel chave no cenário a ser modelado.

3.2 TEOREMA DE BAYES

O Teorema de Bayes relaciona as probabilidades de A e B com suas probabilidades condicionais, e é definido como:

$$P(A/B) = \frac{P(B/A)P(A)}{P(B)} \quad (3.1)$$

Onde,

$P(A)$ é a probabilidade a priori de A, ou seja, antes de considerar o evento condicional

B;

$P(B)$ é a probabilidade de B, e atua como uma constante de normalização;

$P(A|B)$ é a probabilidade condicional de A, dada a ocorrência de B. É chamada de

probabilidade posterior, pois a ocorrência de A depende da ocorrência de B;

$P(B|A)$ é a probabilidade condicional de B, dada a ocorrência de A.

Se $P(B) = 0$ então $P(A/B)$ não estará definido, pois não faz sentido condicionar a ocorrência de um evento A à ocorrência de um evento B impossível.

3.3 TEORIA DOS GRAFOS

Segundo Barber (2010), um grafo G consiste de vértices (nós) e linhas entre os vértices. Os grafos podem ser direcionados e não direcionados, dependendo da existência ou não de direção das linhas. As Figuras 3.1 e 3.2 são exemplos.

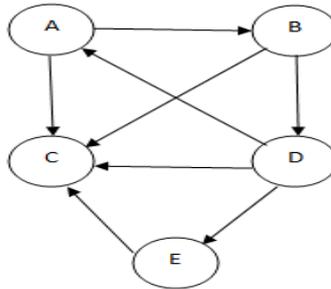


Figura 3.1–Grafo direcionado

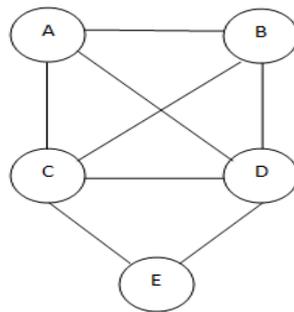


Figura 3.2–Grafo não direcionado

Um caminho de A para B é uma sequência de nós que conectam A e B. Um ciclo é um caminho que começa e termina no mesmo nó. Vale ressaltar que o ciclo deve necessariamente conter mais de dois nós e, caso o grafo não possua ciclo, é chamado acíclico.

Um grafo acíclico direcionado não possui ciclo e suas arestas são direcionadas. O sentido da aresta indica a relação de dependência entre os nós, ou seja, se uma aresta parte de um nó A para um nó B, então A é dito pai de B, assim como B é filho de A. Se um determinado nó não possui pai, ele é chamado de nó raiz. As dependências entre os nós são quantificadas pelas probabilidades condicionais, Gomes (2011).

Para exemplificar, a Figura 3.3 ilustra as relações de dependências entre as variáveis. Note-se que os pais de A_5 são A_1 , A_2 e A_3 . O pai de A_7 e de A_8 é o A_5 . Em contrapartida, A_5 é filho de A_1 , A_2 e A_3 . As variáveis A_1 , A_2 e A_3 são chamadas de raiz, pois elas não possuem pais.

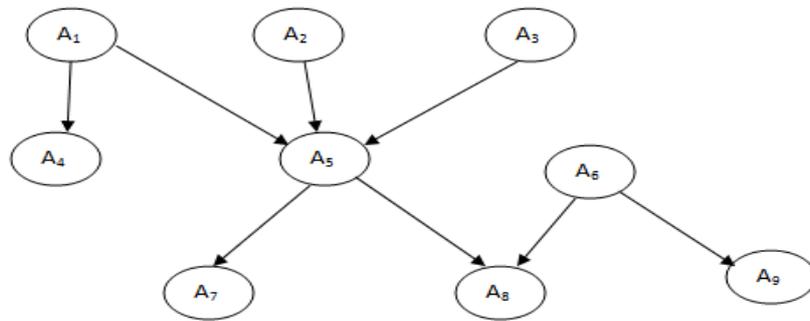


Figura 3.3–Grafo acíclico direcionado

3.4 REDES BAYESIANAS

As redes bayesianas (RB) são grafos acíclicos direcionados (GAD) onde os nós representam as variáveis (discretas ou contínuas), e entre elas existem linhas que as conectam, gerando relações entre as variáveis, Khakzad et al. (2011). As redes bayesianas consistem de um conjunto de variáveis e um conjunto de linhas direcionadas entre as variáveis, Jensen (2001).

Segundo Jones et al. (2010), uma RB é uma ferramenta de inteligência artificial, com a finalidade de modelar incertezas. Tais incertezas podem ser provenientes do entendimento inadequado do sistema, seu conhecimento incompleto e de seu comportamento aleatório.

As redes bayesianas são adequadas para situações de dados escassos, para isto utilizam a opinião de especialistas. Elas são capazes de reduzir incertezas através da atualização das probabilidades, assim como visualizar as dependências entre as variáveis. Outra vantagem das RB é a possibilidade de se adicionar novos objetos, pois seu modelo é flexível, permitindo a modificação dos nós.

Para o cálculo de uma rede bayesiana pode-se utilizar o software Netica. Este software é de fácil manuseio. O nó raiz recebe as probabilidades, que devem ser utilizadas em porcentagem. A cada nó filho deve-se distinguir o portão. O valor do nó falho é encontrado clicando no botão compilar. Através do CTRL + B é possível visualizar uma tabela de probabilidades de todos os nós, Estevão (2013).

O campo de aplicação de uma RB é amplo. Seu modelo é capaz de lidar com sistemas de alta complexidade. A Figura 3.4 exemplifica uma rede bayesiana modelada no software Netica.

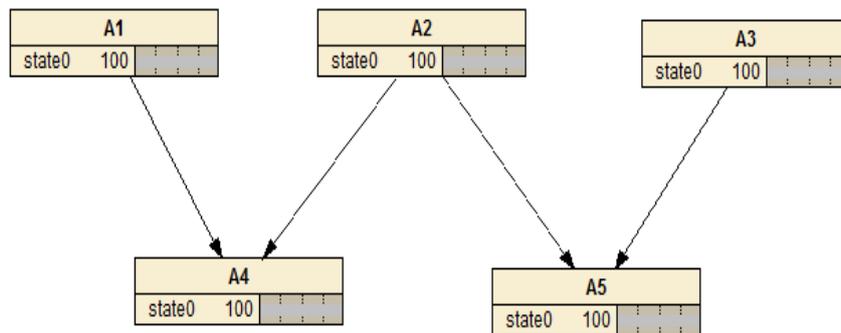


Figura 3.4 – Rede Bayesiana elaborada no Netica

A RB consiste de parte qualitativa e quantitativa. Segundo Bobbio et al. (2001), a parte qualitativa é representada pelo grafo acíclico direcionado e a quantitativa, pela probabilidade condicional. A Figura 3.5 mostra a parte qualitativa de uma RB, onde A_1 e A_2 são nós raízes e pais de B. As probabilidades de A_1 e A_2 devem ser dadas, pois elas são incondicionais.

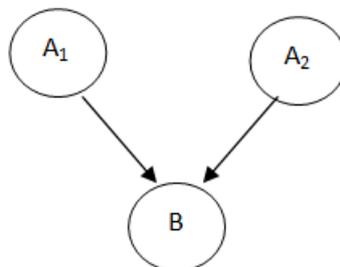


Figura 3.5–Parte qualitativa das redes bayesianas

3.5 VARIÁVEIS ALEATÓRIAS

A variável aleatória se divide em discreta e contínua. Uma variável aleatória X é considerada discreta se assumem valores que podem ser enumerados. Em contrapartida, uma variável aleatória X é dita contínua se existe uma função $f(x) \geq 0$ tal que

$$F_X(X) = \int_{-\infty}^x f_X(t)dt, \forall X \in R \quad (3.2)$$

Assim, X pode assumir uma quantidade não enumerável de valores e a função f_X é chamada de função densidade probabilidade de X . Neste trabalho, nos ateremos a tratar das variáveis aleatórias contínuas, visto que as mesmas serão necessárias para a resolução dos problemas propostos. Segundo Montgomery e Runger (1999), para uma variável aleatória contínua X , uma função densidade de probabilidade é uma função tal que

$$(1) f(x) \geq 0$$

$$(2) \int_{-\infty}^{+\infty} f(x)dx = 1 \quad (3.3)$$

$$(3) P(a \leq X \leq b) = \int_a^b f(x)dx = \text{área sob } f(x) \text{ de } a \text{ e } b \text{ para qualquer } a \text{ e } b$$

3.5.1 DISTRIBUIÇÕES DE PROBABILIDADES DE UMA VARIÁVEL ALEATÓRIA CONTÍNUA

Serão observados abaixo conceitos sobre distribuições de probabilidades. Tais conceitos servem para auxiliar na escolha da distribuição mais adequada ao problema que será proposto adiante. Dependendo do problema, diferentes distribuições de probabilidades podem ser utilizadas para as variáveis independentes, tais como, Uniforme, Weibull, Exponencial, Normal e Lognormal. Estas distribuições citadas, serão definidas abaixo.

3.5.1.1 DISTRIBUIÇÃO UNIFORME

A variável aleatória X tem distribuição uniforme de probabilidades no intervalo $[a,b]$ se a função densidade $f(x)$ for

$$f(x) = \begin{cases} \frac{1}{b-a}, & \text{se } a \leq x \leq b \\ 0, & \text{para outros valores de } x \end{cases} \quad (3.4)$$

A Figura 3.6 representa o gráfico da função densidade de probabilidade de uma variável aleatória com distribuição uniforme no intervalo $[a,b]$.

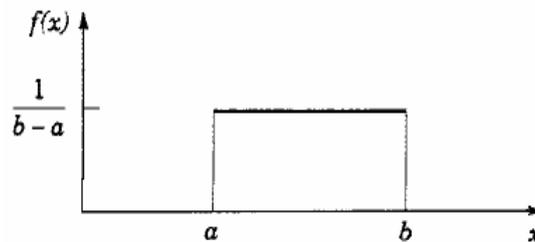


Figura 3.6: Função densidade de probabilidade contínua uniforme, Montgomery e Runger (1999)

3.5.1.2 DISTRIBUIÇÃO DE WEIBULL

Criada por Ernest Hjalmar Wallodi Weibull (1887-1979), esta distribuição foi estudada a partir do artigo *A Statistical Distribution Function of Wide Applicability*, publicada no *Journal of Applied Mechanics*, em 1951, baseando-se nos estudos sobre resistência de aços.

A distribuição de Weibull possui as seguintes utilidades, segundo Benck et. al (2008): 1) representa falhas típicas de partida (mortalidade infantil), falhas aleatórias e falhas devido aos desgastes; 2) obtém parâmetros significativos da configuração das falhas; 3) representação gráfica simples.

A distribuição de Weibull é utilizada para modelar o tempo até uma falha de muitos sistemas físicos diferentes e define-se, segundo Montgomery e Ranger (1999), como: a variável aleatória X com função densidade de probabilidade

$$f(x) = \frac{\beta}{\delta} \left(\frac{x}{\delta}\right)^{\beta-1} e^{-(x/\delta)^\beta} \text{ para } x > 0 \quad (3.5)$$

tem uma distribuição de Weibull com parâmetros de escala $\delta > 0$ e parâmetro de forma $\beta > 0$. Quando $\beta = 1$ a distribuição de Weibull é idêntica à distribuição exponencial. Para calcular as probabilidades, frequentemente utiliza-se a função de distribuição cumulativa que será definida abaixo:

Se X tiver uma distribuição de Weibull, com parâmetros δ e β , então a função distribuição cumulativa de X será

$$F(x) = 1 - e^{-\left(\frac{x}{\delta}\right)^\beta} \quad (3.6)$$

A Figura 3.7 mostra a flexibilidade da distribuição de Weibull representada pelos gráficos das funções densidade de probabilidade.

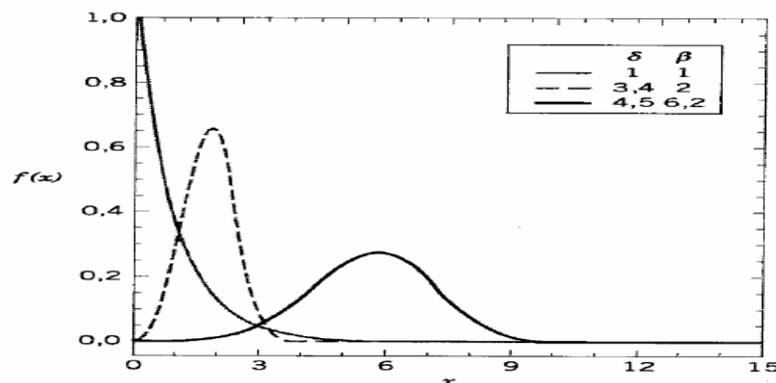


Figura 3.7: Funções densidade de probabilidade de Weibull para valores selecionados de δ e β , Montgomery e Runger (1999)

3.5.1.3 DISTRIBUIÇÃO EXPONENCIAL

A variável aleatória X tem distribuição exponencial com parâmetro $\theta > 0$, onde a função densidade de probabilidade exponencial apresenta-se da seguinte forma

$$f(x) = \lambda e^{-\lambda x} \text{ com } \lambda > 0, X \geq 0 \quad (3.7)$$

A função de distribuição de probabilidade é do tipo:

$$F(X) = \int_0^{\infty} \lambda e^{-\lambda X} = 1 - e^{-\lambda X} \quad (3.8)$$

A distribuição de probabilidade exponencial possui as seguintes características: não é simétrica, a variável aleatória assume somente números positivos e é definida por apenas um único parâmetro, λ . A Figura 3.8 mostra a representação gráfica da distribuição exponencial.

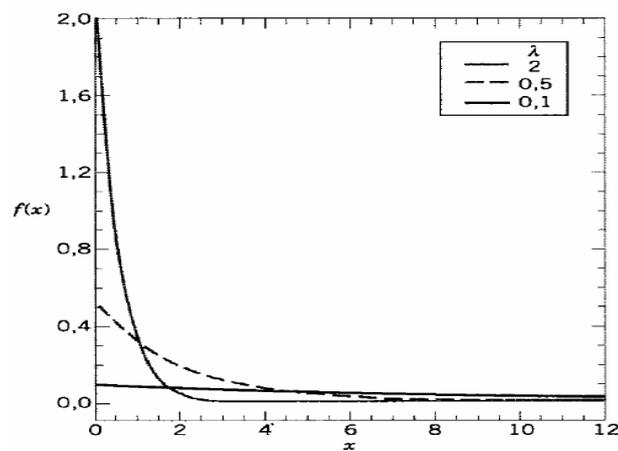


Figura 3.8: Função densidade de probabilidade de uma variável aleatória exponencial para valores selecionados de λ , Montgomery e Runger (1999).

3.5.1.4 DISTRIBUIÇÃO NORMAL

A distribuição normal também conhecida como distribuição gaussiana ou curva em forma de sino, é a mais importante das distribuições de probabilidades. Gauss deduziu matematicamente a distribuição normal como distribuição de probabilidade dos erros de observação, denominando-a como lei normal dos erros, [Correa, 2003]. Uma variável aleatória X , com função densidade de probabilidade

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \text{ para } -\infty < x < \infty \quad (3.9)$$

Tem uma distribuição normal, com parâmetros μ , em que $-\infty < \mu < \infty$ e $\sigma > 0$. Também

$$E(X) = \mu \text{ e } V(X) = \sigma^2 \quad (3.10)$$

A notação $N(\mu, \sigma^2)$ quer dizer uma distribuição normal com média μ e variância σ^2 , [Montgomery e Runger, 1999]. Uma variável aleatória normal com $\mu = 0$ e $\sigma^2 = 1$ é chamada de variável aleatória normal padrão e denotada por Z .

A Figura 3.9 refere-se a uma curva normal típica com seus parâmetros descritos graficamente. A curva normal tem forma de sino, como já foi dito, é unimodal e simétrica, e o seu valor de máxima frequência, a moda coincide com o valor da média e da mediana.

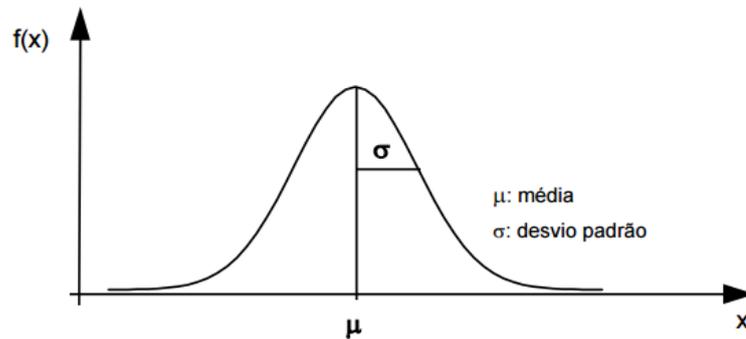


Figura 3.9: Curva normal típica, [Correa, 2003]

3.5.1.5 DISTRIBUIÇÃO LOGNORMAL

A distribuição lognormal é muito utilizada quando se trata de tempo de vida de produtos e de indivíduos. A função densidade de uma variável aleatória Q com distribuição lognormal é dada por,

$$f(t, \mu, \sigma^2) = \frac{1}{Q\sigma\sqrt{2\pi}} \exp\left\{-\frac{[\log Q - \mu]^2}{2\sigma^2}\right\} : Q > 0 \quad (3.11)$$

A Figura 3.10 representa a função densidade de uma distribuição de probabilidade lognormal.

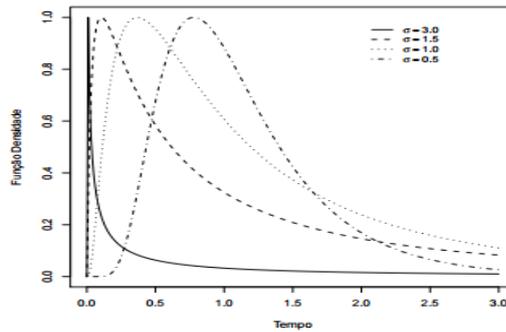


Figura 3.10: Função densidade lognormal, Martins (2013)

Segundo Henley e Kumamoto (1981), quando a variação nos dados é caracterizada por fatores ou porcentagens, então a lognormal é uma distribuição apropriada para descrever os dados adequadamente. Como por exemplo, se Q é uma variável aleatória, que tem um intervalo entre $Q_L = Q_0/K$ e $Q_U = Q_0 K$ onde Q_0 é a mediana e K é uma constante de fator de erro maior que 1, então a lognormal é uma distribuição natural.

Segundo Wash 1400, se X representa a variável aleatória que pode variar por fatores no seu erro, por exemplo, tendo um intervalo possível entre X_0/f e $X_0 \cdot f$, onde X_0 é algum valor de referência do ponto médio e f algum fator, então uma lognormal é uma candidata natural a ser utilizada.

A distribuição lognormal é comumente usada para descrever dados que podem variar por fatores, assim como a distribuição normal é comumente utilizada para tratar de dados que podem variar pela adição ou subtração de incrementos.

3.5.2 MÉDIA E VARIÂNCIA DE UMA VARIÁVEL ALEATÓRIA CONTÍNUA

A média, valor esperado ou esperança matemática da variável aleatória contínua X , representada por μ ou $E(X)$, é calculada por:

$$\mu = E(X) = \int_{-\infty}^{+\infty} X f(X) dX \tag{3.12}$$

Seja X uma variável aleatória contínua com média $\mu = E(X)$. Então a variância de X , anotada por σ^2 ou $V(X)$ é definida por:

$$\sigma^2 = V(X) = \int_{-\infty}^{+\infty} (X - \mu)^2 \cdot f(X) dx = \int_{-\infty}^{+\infty} x^2 \cdot f(X) dX - \mu^2 \quad (3.13)$$

O desvio padrão da variável aleatória contínua X , denotado por σ , é a raiz quadrada da variância.

Trataremos agora dos métodos de propagação de incertezas disponíveis na literatura. Tais métodos auxiliam na tomada de decisões, em análise probabilística de segurança, visando realizar os cálculos para a indisponibilidade de sistemas de segurança de centrais nucleares.

Algumas características dos modelos em que incertezas devam ser consideradas influenciam na escolha do método de propagação, tal como, se pelo menos uma, das variáveis de entrada do modelo, for discreta, os métodos de integração numérica, aproximação por séries de Taylor, não devem ser usados, Rocquigny (2008).

3.6 MÉTODO DOS MOMENTOS

O método dos momentos é bastante simples e intuitivo. Introduzido por Karl Pearson em 1902, consiste em igualar os momentos amostrais aos populacionais. Ao final desta operação obtemos os parâmetros da distribuição de probabilidade dada.

Os momentos são integrais ponderadas de função densidade que descrevem várias propriedades geométricas da função densidade, Shooman (1990).

O valor esperado é dado pelo cálculo dos vários momentos da distribuição de probabilidade e é definido por

$$E(x) = \int_a^b x f(x) dx \quad (3.14)$$

sendo $a < x \leq b$ e $f(x)$ a função densidade.

Para uma variável aleatória discreta x onde $x = x_1, x_2, \dots, x_n$ o valor esperado é dado por

$$E(x) = \sum_{i=1}^n x_i f(x_i) \quad (3.15)$$

Sendo necessário um certo nível de precisão para estimar a variância, métodos determinísticos baseados em integração numérica, ou aproximação por Taylor não são eficazes, Rocquigny et. al (2008). Os métodos de simulação, principalmente SRS (*Simple Random Sampling*) e o LHS (*Latin Hypercube Sampling*), são os mais apropriados.

A função geratriz de momentos de uma função densidade de probabilidades para o caso contínuo é dada por:

$$M_x(t) = \int_{-\infty}^{+\infty} e^{tx} f(x) dx \quad (3.16)$$

em que $f(x)$ é a função densidade de probabilidade.

A interpretação para o caso discreto é dado por:

$$M_x(t) = \sum_{i=1}^n e^{tx_i} f(x_i) \quad (3.17)$$

em que $f(x)$ é a função densidade de probabilidade, Shooman (1990).

3.7 MÉTODO DE MONTE CARLO

O Método de Monte Carlo (MMC) é uma ferramenta matemática que usa números aleatórios para simular problemas que podem ser representados por processos estocásticos. É muito útil para simular problemas que dependam de fatores aleatórios. Este método é muito utilizado em diversas áreas de conhecimento, como por exemplo, em engenharia, física, administração, Yoriyaz (2009).

Oficialmente, este método surgiu em 1949, escrito por Metropolis e Ulam através do artigo “The Monte Carlo Method”, Metropolis e Ulam (1949), para solução de problemas nos quais o tratamento analítico torna-se inviável. O nome dado foi em homenagem ao famoso cassino Monte Carlo, fundado em 1862, situado na cidade de Mônaco, conhecida mundialmente como a capital dos jogos de azar, devido a uma roleta, um gerador de números aleatórios, Yoriyaz (2009).

O método de Monte Carlo fornece uma solução para qualquer tipo de problema, independentemente de sua complexidade, dimensão, ou não linearidade, Jahani et al. (2014). Segundo Papaioannou et al. (2015) o método de Monte Carlo é robusto e simples, sendo capaz de manipular qualquer modelo, independentemente de sua complexidade.

Para efetuar a simulação de Monte Carlo, segundo Werner et. al (2011), é necessário realizar os seguintes passos: 1) Determinar as variáveis que serão utilizadas na simulação; 2) Determinar as distribuições de probabilidade das variáveis que serão simuladas; 3) Estabelecer as relações entre variáveis; 4) Calcular o número de simulações (rodadas) a serem obtidas, considerando o erro aceitável e a confiabilidade; 5) Rodar a simulação. Cada rodada é um cenário possível e consistente baseado nos supostos estabelecidos do modelo. O resultado de cada rodada deve ser guardado; 6) Analisar estatisticamente os resultados. Por exemplo, medidas estatísticas, probabilidade de que os resultados assumam certos valores, histograma ou gráfico de probabilidades, lucro esperado, entre outros.

A Figura 3.11 mostra um fluxograma que representa os passos a serem dados para se realizar uma simulação por Monte Carlo.

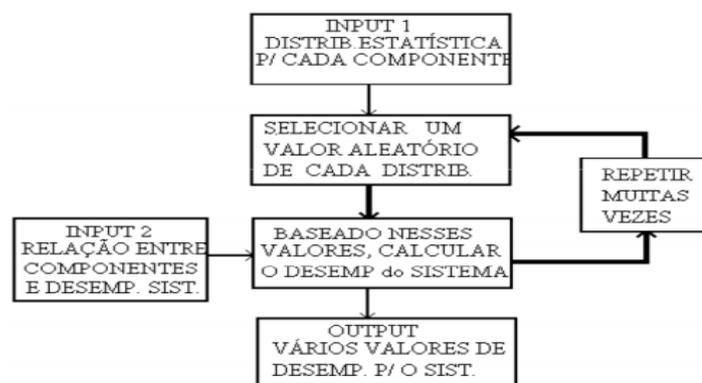


Figura 3.11: Fluxograma do método de simulação de Monte Carlo, Werner (2010)

Segundo Yoriyaz (2009), para a utilização de Monte Carlo são necessários alguns componentes primários:

- Função Densidade de Probabilidade (FDP);
- Gerador de Números Aleatórios (GNA);
- Técnicas de Amostragem (TA).

As variáveis modeladas devem ser descritas por uma FDP. As FDP são funções não negativas que representam a distribuição de probabilidade, quando tratamos de variável aleatória contínua. A amostragem obtida deve ser aleatória. Assim, utiliza-se computacionalmente o segundo tópico mencionado acima, o GNA.

Em MMC, após a escolha da FDP, é necessária a utilização dos GNA para os parâmetros de entrada. Os números aleatórios são elementos básicos necessários na simulação de quase todos os sistemas discretos. Sua geração em computadores torna-se inapropriada, visto que a característica de qualquer sequência de números aleatórios está no fato dela não ser reproduzida. Já os procedimentos computacionais fornecem sequências que podem ser reproduzidas. Assim, as sequências de números aleatórios tratadas neste trabalho serão denominados pseudoaleatórias.

Os números pseudoaleatórios constituem uma sequência de números que devem ser computacionalmente eficientes, uma vez que as simulações podem necessitar de milhões de números aleatórios a cada execução e seus valores devem ser independentes e uniformemente distribuídos.

A técnica mais comum empregada na geração de números aleatórios se inicia com um valor x_0 , chamado de semente, e então se faz uso de uma relação recursiva para a determinação do valor final x_n , $n \geq 1$, com

$$x_n = ax_{n-1} \text{ modulo } m \quad (3.18)$$

onde a e m são inteiros positivos dados e ax_{n-1} é dividido por m . Assim cada x_n é também $0, 1, 2, \dots, m - 1$ e x_n/m é chamado de número pseudoaleatório, Ross (2006).

Embora esta sequência seja considerada aleatória, são de fato números pseudoaleatórios. As sequências de números pseudoaleatórios possuem uma grande vantagem sobre as que são realmente aleatórias, pois elas podem ser utilizadas inúmeras vezes, com a finalidade de produzir os mesmos números.

Para a criação de uma nova sequência, basta fazer a modificação do elemento semente. Logo, os geradores de números aleatórios permitem um controle adicional sobre a possibilidade de se reproduzir os resultados.

Uma das grandes vantagens do Método de Monte Carlo sobre outras técnicas numéricas é a possibilidade de se avaliar o erro das estimativas. Outra vantagem se dá por não ser necessário o conhecimento prévio das expressões analíticas que modelam o problema proposto.

A simulação por Monte Carlo permite analisar sistemas por redes bayesianas que não poderiam ser analisados analiticamente. A técnica de experimentação numérica de Monte Carlo consiste na introdução de N amostras da variável aleatória na entrada de um dado sistema para gerar N amostras aleatórias da variável de saída, Macedo (2010). As variáveis de entradas são modeladas por uma função de distribuição de probabilidade pré-determinada.

Uma desvantagem para o uso do método de Monte Carlo é a demanda computacional ser muito alta, mesmo quando se trata de probabilidades de falhas pequenas. A eficiência deste método pode ser melhorada com a aplicação do método de redução de variância, como por exemplo, amostragem por importância, Papaioannou et al. (2015).

Encontram-se na literatura três tipos de técnicas de propagação de incertezas em Monte Carlo: simulação Monte Carlo clássica, método de Monte Carlo Bayes e método de inicialização (bootstrap). Estes métodos serão descritos nas seções posteriores.

3.7.1 SIMULAÇÃO DE MONTE CARLO CLÁSSICA

Sejam (x_1, x_2, \dots, x_n) variáveis aleatórias, tem-se o caso geral da estimação do modelo como sendo,

$$Y = f(x_1, x_2, \dots, x_n) \quad (3.19)$$

O método de Monte Carlo clássico se baseia sobre os modelos probabilísticos clássicos, para caracterizar incertezas x_i elementos que são construídos baseados apenas em dados, Modarres (2006). Para cada elemento x_i , é associada uma distribuição, baseadas nos dados de falha real. Porém, se não há dados, devemos tratar Y como variável aleatória.

Seguem quatro passos, sugeridos por Modarres (2006), para construir o limite de confiança para Y : **1)** Para cada x_i elementos de Y , selecione um ponto de dados observados ou uma estimativa de pontos (exemplo: uma estimativa de probabilidade máxima); **2)** Calcular a correspondente estimativa clássica de Y em (4.6); **3)** Repetir os passos anteriores um número de vezes suficientemente grande, n , para obtermos um grande número de amostras de Y ; **4)** Usando as amostras obtidas no terceiro passo, e escolhendo o nível de confiança $(1 - \alpha)$, deve-se construir o limite de confiança para Y .

3.7.2 SIMULAÇÃO DE MONTE CARLO BAYES

A fim de reduzir o custo computacional com o uso de Monte Carlo e de ter mais controle no processo de amostragem, criaram-se técnicas cuja finalidade é reduzir a variância. Porém, o controle continua não sendo total, pois se continua trabalhando com valores aleatórios. Técnicas de redução de variância serão descritas adiante.

3.7.2.1 AMOSTRAGEM POR HIPERCUBO LATINO

A amostragem por hipercubo latino foi proposta por McKay et.al. (1979) e funciona como uma técnica de redução de variância. Ela é utilizada da seguinte forma: o domínio de cada variável aleatória x_k com $k = 1, \dots, m$, é dividido em n intervalos de igual probabilidade $\frac{1}{n}$.

O número n de intervalos deve ser igual ao tamanho da amostra de interesse, ou seja, igual ao número de simulações.

Em suma, esta amostragem se baseia na estratificação da distribuição amostral, com igual probabilidade de ocorrência e sorteiam-se aleatoriamente valores para cada um destes estratos. A amostra hipercúbica é constituída por esses valores sorteados aleatoriamente.

A eficácia do hipercubo latino se dá, pelo fato de ele possuir uma estratificação densa ao longo das variáveis incertas, com um tamanho de amostra relativamente pequeno, [Sallaberry, 2007].

Foi desenvolvida, por [Saliby, 1980], uma técnica alternativa para a redução da variância, chamada amostragem descritiva. Segundo Maletta (2005), na abordagem descritiva, rompe-se completamente a seleção aleatória da amostra, utilizando como base a escolha determinística dos valores. Estes são escolhidos como pontos centrais dos mesmos estratos utilizados no hipercubo latino.

McKay et. al (1979) chegaram à conclusão que a amostragem por hipercubo latino possui mais vantagens em comparação a outros métodos, pois pode-se reduzir seu número de simulações consideravelmente, para atingir o mesmo nível de precisão que outros métodos por eles analisados.

A desvantagem deste método é a falta de possibilidade de se aumentar o tamanho da amostra, utilizando a amostra já disponível mantendo as propriedades de estratificação que tornam a amostragem por hipercubo latino tão eficaz, Sallaberry (2007). Com isto, pode-se recair num problema. Amostras pequenas podem fornecer resultados estatísticos incompletos (não aceitáveis), enquanto que amostras grandes demais podem levar a um esforço computacional custoso.

3.7.2.2 AMOSTRAGEM POR IMPORTÂNCIA

Existem inúmeras maneiras de se reduzir a variância de estimadores de Monte Carlo. Isto auxilia na redução do tempo para simular um determinado modelo. A amostragem por importância tem sido muito utilizada para desempenhar esta função. Antes de esta técnica ser elaborada, a geração da amostra era totalmente aleatória e era denominada amostragem aleatória simples.

Segundo Vieira (2006), a amostragem por importância consiste em forçar a seleção de um maior número de amostras nas partes mais importantes do problema. Isto

é feito, inserindo uma nova função distribuição. O objetivo desta técnica é deslocar a distribuição para as áreas de maior interesse, aumentando assim a convergência do método. Para que não haja alteração nos resultados esperados, torna-se necessário corrigir os valores por um fator peso.

A fim de ilustrar o princípio de amostragem por importância, considere a integral, segundo [Vieira, 2006] :

$$\phi = \int_{-\infty}^{\infty} f(x) i(x) dx \quad (3.20)$$

Deve-se introduzir uma função importância $i(x)$ da seguinte forma:

$$f(x) = \frac{f(x)}{i(x)} i(x) = \frac{\int_{-\infty}^{\infty} f(x) i(x) dx}{i(x)} \frac{f(x) i(x)}{\int_{-\infty}^{\infty} f(x) i(x) dx} \quad (3.21)$$

A distribuição modificada é dada por:

$$g(x) = \frac{f(x) i(x)}{\int_{-\infty}^{\infty} f(x) i(x) dx} \quad (3.22)$$

ou,

$$f(x) = \frac{f(x)}{g(x)} g(x) \quad (3.23)$$

onde $\frac{f(x)}{g(x)}$ é o peso da correção. Para a nova função distribuição, deve ser calculado o fator de normalização, que para este caso será chamado de J .

$$J = \int_{-\infty}^{\infty} f(x) i(x) dx \quad (3.24)$$

Substituindo J na equação (4.6)

$$g(x) = \frac{f(x)i(x)}{J} \quad (3.25)$$

3.7.3 MÉTODO DE SIMULAÇÃO BOOTSTRAP

O método bootstrap foi introduzido por Efron (1979), sendo muito utilizada em diferentes situações estatísticas. O objetivo deste método é obter, através da reamostragem do conjunto de dados originais, um novo conjunto de dados.

A reamostragem consiste em formar uma nova amostra, realizando sorteio, com reposição, de dados pertencentes a uma amostra retirada anteriormente. Com a reamostragem é possível obter diferentes alternativas para encontrar o desvio padrão e o intervalo de confiança através da análise de dados.

O método bootstrap pode ser usado para estimar o erro padrão $\sigma_{\hat{\theta}}$, onde $\hat{\theta}$ é uma estimativa do parâmetro θ , assim como pode ser usado para encontrar o intervalo de confiança sobre o parâmetro θ , Montgomery e Runger (1999).

Segundo Bastos (2013), este método é aplicável em situações em que os métodos tradicionais não podem ser empregados, por inúmeras razões, como por exemplo, distribuição inadequada, heterogeneidade de variâncias, distribuição de amostragem da quantidade amostral de interesse não conhecida, dentre outras razões.

Não é necessário utilizar o método de bootstrap sozinho, ele pode ser empregado como um complemento a conclusões de outros métodos. Para que seus resultados sejam satisfatórios, é importante analisar os valores de entrada para amostra. Uma amostra de tamanho n possui uma probabilidade de ser sorteada igual a $\frac{1}{n}$.

As vantagens em utilizar o método bootstrap são:

- Possibilidade de se obter respostas mais precisas;
- Generalidade do método, pois necessita de menos suposições;

- Possibilidade de se utilizar problemas onde a distribuição de probabilidade é desconhecida, pois é um modelo que não exige a análise de uma fórmula para cada problema.

Segundo Bastos (2013), este método se divide em não paramétrico e paramétrico. No método de bootstrap não paramétrico a amostragem é feita repondo a amostra original. Considera que a função de distribuição da variável aleatória é desconhecida. O objetivo é encontrar pseudoamostras de mesmo tamanho da amostra original. Este processo é repetido inúmeras vezes até que se obtenha o mesmo número de estimativas. Estas estimativas representam uma amostra da distribuição do estimador, permitindo realizar inferências sobre o parâmetro de interesse.

A fórmula não paramétrica é a mais usada. A Figura 3.12 ilustra o método não paramétrico sob a visão de Bastos (2013).

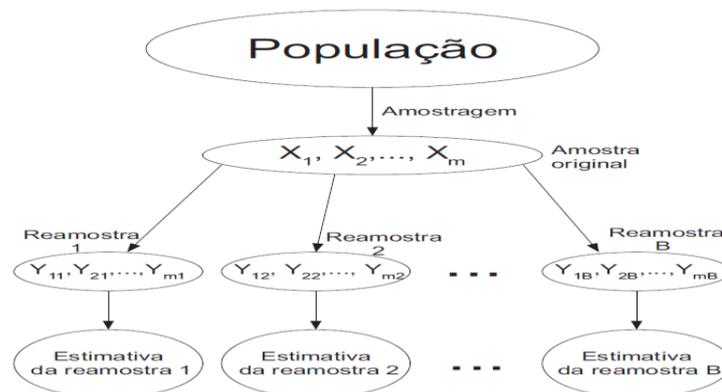


Figura 3.12 Ilustração do método de bootstrap não paramétrico, Bastos (2013).

O método de bootstrap paramétrico é similar ao método de Monte Carlo. Ele se aplica quando a distribuição da variável aleatória é conhecida. Assim, ele se baseia em gerar reamostras da distribuição de probabilidade usando como parâmetros as estimativas dos mesmos encontrados através da amostra original.

O bootstrap paramétrico é mais restrito, pois se baseia em uma distribuição para os dados amostrais. A Figura 3.11 ilustra o resumo do método de bootstrap paramétrico, para um melhor entendimento.

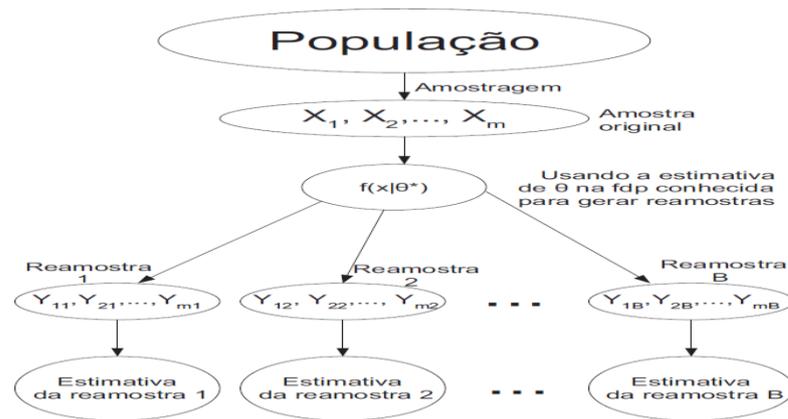


Figura 3.11 Ilustração do método de bootstrap paramétrico, Bastos (2013).

3.8 MÉTODO DE SUPERFÍCIE DE RESPOSTA

O método de superfície de resposta é um conjunto de técnicas matemáticas e estatísticas que são muito usadas ao analisar e modelar eventos cuja resposta de interesse é influenciada por várias variáveis e o objetivo é otimizar esta resposta, [Montgomery e Runger, 1999].

Este método é aplicado quando o problema a ser estudado é muito complexo e trabalhar com simulação de Monte Carlo torna-se inviável. Assim, será definida a superfície de resposta como a representação geométrica obtida quando se trata, o gráfico de uma variável resposta, como uma função de dois ou mais fatores quantitativos, Cecon e Silva (2011). Esta função pode ser definida como:

$$Y = f(x_1, x_2 \dots x_k) + \varepsilon \quad (3.26)$$

onde ε é o erro aleatório observado na resposta Y . O valor esperado da resposta Y é representado por $E(Y)$ e é dado por:

$$E(Y) = f(x_1, x_2 \dots x_k) = \eta \quad (3.27)$$

logo, a superfície dada por

$$\eta = f(x_1, x_2 \dots x_k) \quad (3.28)$$

chamada de superfície de resposta.

Segundo Cecon e Silva (2011), ao usar uma superfície de resposta deve-se levar em conta alguns pressupostos, que são: 1) Os fatores que são críticos para o processo são conhecidos; 2) A região em que os fatores influem o processo é conhecida; 3) Os fatores variam continuamente ao longo da faixa experimental escolhida; 4) Existe uma função matemática que relaciona os fatores à resposta medida.

Cecon e Silva (2011) listaram também algumas das limitações que este método possui: 1) Grandes variações dos fatores podem resultar em conclusões falsas; 2) A região de ótimo pode não ser determinada devido ao uso de uma faixa muito estreita ou ampla; 3) Como em qualquer experimento, resultados distorcidos podem ser obtidos se os princípios clássicos da experimentação não forem seguidos (casualização, repetição e controle local); 4) Superestimar a computação: o pesquisador deve ter cuidado ao chegar às conclusões dos resultados. Deve utilizar seu conhecimento prévio para tomar decisões adequadas.

3.9 LÓGICA FUZZY

A lógica fuzzy, também chamada de lógica difusa ou nebulosa foi introduzida em 1930 por Jan Lukasiewicz, filósofo e lógico polonês. Já em 1965, Lotfi Zadeh (Universidade da Califórnia, Berkeley) publicou o artigo *Fuzzy Sets*, que ficou conhecido como o que originou a lógica *fuzzy*.

A lógica *fuzzy* possui como foco principal a representação da lógica e da racionalidade humana ao resolver problemas de alta complexidade. Os algoritmos baseados na lógica *fuzzy* são diferentes dos métodos determinísticos e probabilísticos. A lógica *fuzzy* trabalha com novos conceitos, como por exemplo, variáveis linguísticas e a distribuição de possibilidade, o que melhora a acurácia dos cálculos efetuados.

Segundo Lima (1999), para estudar lógica *fuzzy*, é necessário o entendimento de cinco diferentes símbolos conceituais, que são conjunto de elementos, variável

linguística, termo linguístico, intervalo numérico mensurável e atribuição numérica subjetiva.

Na teoria clássica, desenvolvida por Aristóteles, os conjuntos são denominados “crisp” e um dado elemento do universo pertence ou não pertence ao referido conjunto. Já na teoria de conjuntos *fuzzy* existe um grau de pertinência de cada elemento a um determinado conjunto. A variável linguística é um rótulo para um atributo dos elementos, como por exemplo, idade, nível de estoque.

O termo linguístico de uma variável linguística, corresponde a um adjetivo ou a um advérbio, em um conjunto de termos linguísticos, como “jovem”, ou “velho”, associado com a idade. Intervalo numérico mensurável, conhecido como conjunto referencial para a medição de um atributo particular, de um conjunto de elementos, como por exemplo, “[0,50] anos” quando se refere à idade. E, por fim, atribuição numérica subjetiva ou valor de pertinência, que é o grau com que um elemento pertence ao conjunto de elementos, rotulados por uma variável linguística e identificados pelo termo linguístico, Lima (1999).

Segundo Barbalho (2001), as variáveis linguísticas cumprem na lógica difusa o mesmo papel que as variáveis numéricas nos modelos matemáticos convencionais, com a diferença de que os valores que podem assumir são conceitos expressos em linguagem natural, como por exemplo, “alto”, “baixo”, “quente”, entre outros. A Figura 3.12 ilustra todo o sistema lógico *fuzzy*, Jané (2004).

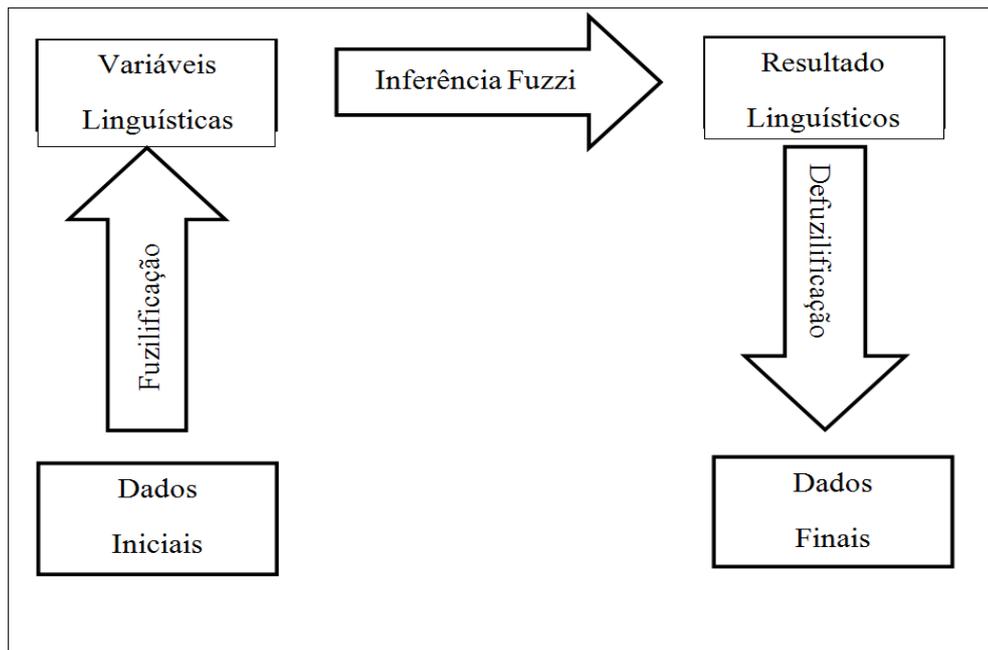


Figura 3.12 – Estrutura do sistema da lógica *fuzzy*, Jané (2004)

Uma proposição lógica possui, tradicionalmente, dois extremos: completamente verdadeiro ou completamente falso. Ao contrário da lógica convencional, a lógica *fuzzy* utiliza a ideia de que todas as coisas admitem graus de pertinência. Porém, na lógica *fuzzy* o grau de verdade varia de 0 a 1, o que leva a premissa a ser parcialmente verdadeira ou parcialmente falsa.

O objetivo deste método é gerar uma saída lógica a partir de um conjunto de entradas não precisas. O grau de pertinência 0 indica que o valor não pertence ao conjunto. O grau 1 indica uma representação completa deste conjunto.

Seja um conjunto *fuzzy* A , de um universo E , cujos elementos são denotados por x_i . A função de pertinência associada a este conjunto é definida por:

$$\forall x \in A : \mu_A(x) \in [0,1] \quad (3.29)$$

onde μ_A é a função de pertinência.

Considere um conjunto A e um elemento x com relação a esse conjunto. As expressões abaixo demonstram como é a tomada de decisão para uma teoria clássica e a lógica *fuzzy*, respectivamente.

$$f(x) = \begin{cases} 1, & \text{se, e somente se, } x \in A \\ 0, & \text{se, e somente se, } x \notin A \end{cases} \quad (3.30)$$

$$\mu(x) = \begin{cases} 1, & \text{se, e somente se, } x \in A \\ 0, & \text{se, e somente se, } x \notin A \\ 0 \leq \mu(x) \leq 1, & \text{se } x \in \text{parcialmente a } A \end{cases} \quad (3.31)$$

Assim, pode-se observar que, para a lógica *fuzzy*, o intervalo de pertinência é [0,1] sabendo que 0 significa que o elemento não pertence ao conjunto e 1 significa total pertinência a esse conjunto. Já os elementos que estão entre 0 e 1 indicam graus parciais de pertinência.

A teoria dos conjuntos fuzzy e a simulação de Monte Carlo ajudam a propagar incertezas usando distribuições de possibilidade e probabilidade respectivamente, Zonouz e Miremadi (2006).

Segundo Guimarães (1997), a teoria dos conjuntos fuzzy possibilita quantificar e manipular situações qualitativas, conceitos vagos, ou subjetividade de opiniões. A variável linguística se diferencia da variável numérica por utilizar sentenças ou palavras em lugar de números.

Conforme visto por Jané (2004), todas as operações entre os conjuntos *fuzzy* estão relacionados com suas respectivas funções de pertinência. Seguem abaixo as definições de conjunto *fuzzy* vazio, conjunto *fuzzy* total, equivalências entre conjuntos *fuzzy*, subconjunto *fuzzy*, complemento, união entre conjuntos *fuzzy*, interseção entre conjuntos *fuzzy*, soma exclusiva entre conjuntos *fuzzy* e produto algébrico entre conjuntos *fuzzy*.

Conjunto *fuzzy* vazio: Seja **A** um conjunto fuzzy. Ele será considerado vazio (ϕ), se sua função de pertinência se comportar conforme a equação (4.16):

$$A = \phi \Leftrightarrow \mu_A(x) = 0, \forall x \in A \quad (3.32)$$

Conjunto *fuzzy* total: Seja **A** um conjunto fuzzy. Ele será considerado total em um universo **E**, se sua função de pertinência se comportar conforme a equação (4.20):

$$A = A(E) \Leftrightarrow \mu_A(x) = 1, \forall x \in A \quad (3.33)$$

Equivalência entre conjuntos *fuzzy*: Dois conjuntos fuzzy **A** e **B** são ditos iguais se suas funções de pertinência assumirem valores iguais conforme a equação (3.34):

$$A = B \Leftrightarrow \mu_A(x) = \mu_B(x), \forall x \in E \quad (3.34)$$

Subconjunto *fuzzy*: O conjunto fuzzy **A** é dito subconjunto ou incluído no conjunto fuzzy **B** ($A \subseteq B$), caso ocorra relação conforme a equação (3.35):

$$A \subseteq B \Leftrightarrow \mu_A(x) \leq \mu_B(x), \forall x \in E \quad (3.35)$$

Complemento: O complemento de um conjunto *fuzzy* **A** (\bar{A}) é tal que sua função de pertinência obedece à relação conforme a equação (3.36):

$$\bar{A} \Rightarrow \mu_{\bar{A}}(x) = 1 - \mu_A, \forall x \in E \quad (3.36)$$

União entre conjuntos *fuzzy*: A união de dois conjuntos *fuzzy* **A** e **B** é dada pela união entre suas funções de pertinência conforme equação (3.37):

$$A \cup B \Leftrightarrow \mu_{A \cup B}(x) = \max(\mu_A, \mu_B), \forall x \in E \quad (3.37)$$

Interseção entre conjuntos *fuzzy*: A interseção de dois conjuntos fuzzy **A** e **B** é dada pela interseção de suas funções de pertinência conforme a equação (3.38):

$$A \cap B \Leftrightarrow \mu_{A \cap B}(x) = \min(\mu_A, \mu_B), \forall x \in E \quad (3.38)$$

Soma exclusiva entre conjuntos *fuzzy*: A soma exclusiva entre dois conjuntos *fuzzy* **A** e **B** ($\mathbf{A} \oplus \mathbf{B}$) é dada conforme a equação (3.39):

$$A \oplus B \Leftrightarrow (A \cap \bar{B}) \cup (\bar{A} \cap B) \quad (3.39)$$

Produto Algébrico entre conjuntos *fuzzy*: O produto algébrico entre dois conjuntos *fuzzy* **A** e **B** ($\mathbf{A} \cdot \mathbf{B}$), é calculado através da equação (3.40):

$$A \cdot B \Leftrightarrow \mu_{A \cdot B}(x) = \mu_A(x) \cdot \mu_B(x), \forall x \in E \quad (3.40)$$

A lógica fuzzy se destaca em comparação a outros métodos de propagação de incertezas, por causa das seguintes vantagens: possui solução rápida e barata em alguns casos, é facilmente implementável em microprocessadores, controle de sistemas lineares sem modelos matemáticos, modificada facilmente, pois é baseada em regras e robusta devido ao fato de não requerer entradas precisas.

A etapa de fuzzificação é o primeiro passo a ser considerado. Neste ocorre à transformação dos dados de entrada em suas respectivas variáveis linguísticas. Após a etapa de fuzzificação, inicia-se a fase denominada inferência *fuzzy*, que possui a função de relacionar as possíveis variáveis entre si, cumprindo regras pré-estabelecidas. A última etapa do sistema lógico *fuzzy* é a desfuzzificação, que possui a função de traduzir, em valores numéricos, os resultados obtidos na etapa anterior.

Na etapa de fuzzificação deve-se ter atenção na definição das funções de pertinência para cada variável. Os tipos de espaços mais comuns são os triangulares, trapezoidal e sino. Na etapa de inferência deve ser dada a atenção necessária às proposições (possuem grande importância nos modelos *fuzzy*). A desfuzzificação, última etapa, corresponde à ligação entre as regiões *fuzzy* e o valor esperado, Tibiriçá (2005).

3.10 COMPARAÇÃO ENTRE OS MÉTODOS

Nesta seção será feita a comparação entre os métodos apresentados anteriormente. A análise está baseada nas seguintes divisões: método de Monte Carlo (AHL, AI e Bootstrap), método de momentos e superfície de resposta. A comparação abaixo foi baseada em Modarres (2006).

O método de Monte Carlo possui inúmeras vantagens, tais como, suas aproximações são conceitualmente simples e de fácil utilização, tendo abrangentes fontes de informações na literatura.

A desvantagem do MMC está no custo computacional, que dependendo do problema, pode inviabilizar a simulação. Porém, como já foi mencionado, os computadores estão cada vez melhores, assim como os softwares. Isto reduz a cada dia o custo computacional, o que tem tornado este método muito adequado.

Dependendo da precisão que se deseja, pode ser usado o método de AHL, que podem reduzir drasticamente o tamanho da amostra. As vantagens da AHL são: aumento da precisão na distribuição de saída, como é um método que reduz o custo computacional é muito usado pelos analistas. A desvantagem deste método está na sua complexidade para estabelecer o problema e executá-lo, caso seja um problema complexo.

O método de momentos se baseia na aproximação da série de Taylor e possui a vantagem de, quando a série de Taylor já estiver desenvolvida a análise de sensibilidade e de incerteza serão muito simples. Além disso, a aplicação deste método tem sido amplamente estudada. O problema é que este método fornece soluções locais, ele é mais bem aplicado em problemas simples.

O método de superfície de resposta é útil quando o problema é muito complexo para ser realizada a simulação de Monte Carlo. Com a superfície de resposta é possível ter um controle completo dos modelos de entrada e as análises de incertezas e de sensibilidade são muito simples, uma vez que o modelo de superfície de resposta tenha sido desenvolvido. Algumas vezes, torna-se necessário um grande número de execuções, a correlação entre variáveis pode ser difícil e escolher uma superfície de resposta apropriada a um determinado modelo, pode ser algo de elevado grau de dificuldade.

Tabela 3.1: Comparação entre os métodos de propagação de incertezas

MÉTODO	VANTAGEM	DESVANTAGEM
MOMENTOS	O método de momentos se baseia na aproximação da série de Taylor e possui a vantagem de, quando a série de Taylor já estiver desenvolvida a análise de sensibilidade e de incerteza serão muito simples, Shooman (1990).	Este método fornece soluções locais, ele é bem aplicado em problemas simples.
SUPERFÍCIE DE RESPOSTA	Este método é muito útil quando o problema é muito complexo para ser realizada a simulação de Monte Carlo. Com a superfície de resposta é possível ter um controle completo dos modelos de entrada e as análises de incertezas e de sensibilidade são muito simples, uma vez que o modelo de superfície de resposta tenha sido desenvolvido, Cecon e Silva (2011).	Algumas vezes, torna-se necessário um grande número de execuções, a correlação entre variáveis pode ser difícil e escolher uma superfície de resposta apropriada a um determinado modelo, pode ser algo de elevado grau de dificuldade.
MONTE CARLO	O método de Monte Carlo possui inúmeras vantagens, tais como, suas aproximações são conceitualmente simples e de fácil utilização, tendo abrangentes fontes de informações na literatura, Yoriyaz (2009).	A desvantagem do MMC está no custo computacional, que dependendo do problema, pode inviabilizar a simulação.

Se alguma variável de interesse for multidimensional ou depender do tempo, apenas o método de Monte Carlo será possível. Se pelo menos uma variável de entrada do modelo for uma variável aleatória discreta, os métodos de integração numérica, aproximação por Taylor e métodos baseados sobre o desenvolvimento estocástico, não serão apropriados, (Rocquigny et. al 2008).

O método FORM (método de confiabilidade de primeira ordem) e SORM (método de confiabilidade de segunda ordem) é considerado um dos mais confiáveis métodos computacionais para a confiabilidade estrutural. Estes métodos podem ser usados para calcular a probabilidade de falha utilizando as variáveis aleatórias, evitando assim a integração numérica. Sua precisão geralmente depende de três parâmetros: o raio de

curvatura do ponto de projeto, o número de variáveis aleatórias e o índice de confiabilidade de primeira ordem, Zhao e Ono (1999).

O método FORM baseia-se em aproximações lineares. Já o SORM, baseia-se em aproximações quadráticas. O método de confiabilidade de segunda ordem foi uma tentativa de melhorar a precisão do método de primeira ordem.

Através da lógica *fuzzy* é possível modelar as incertezas através das taxas de falhas dos eventos básicos da AF, que são os nós raízes da RB, através de conjuntos com fronteira nebulosa. Esta técnica se baseia na lógica nebulosa ao invés de se basear na lógica booleana.

3.11 ÁRVORE DE FALHAS

A árvore de falhas pode ser descrita como uma técnica analítica, uma das técnicas mais populares para a análise de segurança, que possui a finalidade de modelar as possíveis falhas de sistemas ou acidentes.

A construção da árvore de falhas é realizada dos eventos para as causas. Através desta técnica, é possível identificar falhas que conduzirão ao Evento Topo (ET). O ET representa uma falha de sistema e deve ser colocado no topo da árvore de falhas.

A análise da árvore de falhas tem por objetivo estudar as possíveis combinações, que podem levar à falha do evento topo. É importante salientar que uma árvore de falhas não representa necessariamente todas as combinações de falhas possíveis em um sistema. Ela inclui apenas as falhas que o especialista consegue identificar, [Guimarães, 1997].

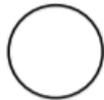
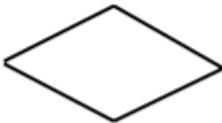
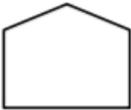
Uma árvore de falhas é um modelo qualitativo que é avaliado quantitativamente usando álgebra booleana para analisar a probabilidade do resultado. Através da análise qualitativa é possível determinar o conjunto de cortes mínimos da AF.

Um corte mínimo é um conjunto de eventos básicos que não pode ser reduzido sem perder a condição de corte e são as combinações mínimas de eventos que quando ocorrem levam à falha do sistema, [Simões Filho, 2006].

3.11.1 Simbologia da árvore de falhas

A Tabela 3.2 mostra os símbolos de eventos primários, que são utilizados para a construção de uma árvore de falhas.

Tabela 3.2 – Diferentes Eventos Primários

Símbolo	Nomenclatura
	Evento Básico
	Evento Condicionante
	Evento não desenvolvido
	Evento Externo

De acordo com as Tabelas 3.2, 3.3 e 3.4, para construção de uma árvore de falhas, podem-se utilizar os seguintes símbolos: diferentes eventos primários, evento intermediário e de transferência e portões lógicos.

O evento básico é representado por um círculo e indica que a falha não pode mais ser subdividida. O evento condicionante, uma elipse, registra qualquer condição ou restrição a qualquer portão lógico. O evento não desenvolvido, losango, indica que devido à falta de informações este evento não será desenvolvido em detalhes. O evento externo significa um evento que se supõe que exista, por exemplo uma mudança de fase num sistema dinâmico.

Tabela 3.3 – Evento intermediário e evento de transferência

Símbolo	Nomenclatura
	Evento Intermediário
	Transferência para dentro
	Transferência para fora

O evento intermediário, representado por um retângulo, ocorrem porque uma ou mais causas antecedentes atuam nos portões lógicos. As transferências indicam que as árvores foram desenvolvidas em folhas adicionais o que permite representar árvores grandes.

Na Tabela 3.4 são mostrados os portões lógicos, que mostram como funciona a modelagem para resultar no evento topo. Para o portão E, a falha na saída ocorrerá apenas se todas as entradas ocorrerem. O portão OU indica que ocorrerá falha na saída se pelo menos uma entrada ocorrer. O portão k/n representa que pelo menos k das n entradas devem ocorrer. E, por fim, a porta inibidora, representada por um hexágono, indica que a saída ocorre quando uma entrada única satisfaz alguma condição.

Tabela 3.4 – Portões Lógicos

Símbolo	Nomenclatura
	Porta OU
	Porta E
	Porta k de n
	Porta Inibidora

4 PROBLEMA INVESTIGADO

A árvore de falhas escolhida para a realização da modelagem foi a de um sistema de segurança de uma usina a água leve típica de segunda geração, o Sistema de Remoção de Calor da Contenção (CHRS).

A Figura 4.1 representa o diagrama simplificado do sistema de remoção de calor da contenção (CHRS). Neste diagrama estão destacadas as válvulas que são automaticamente abertas por sinais, os monitores de radiação (uma amostra de água, de cada trocador de calor é passado por estes monitores de radiação, para analisar se há radiação saindo do sistema), caso haja, as válvulas são automaticamente fechadas. Há também, em destaque, as linhas de descarga para a entrada e saída de ar no sistema do trocador de calor.

A função do CHRS é resfriar a água do poço da contenção, recirculando através do *Containment Spray Recirculation System* (CSRS). Este último é iniciado automaticamente após um acidente de perda de refrigerante (LOCA) e em conjunto com o CHRS disponibiliza meios para remover o calor da água do poço da contenção. Sendo assim, estes sistemas são de grande importância após a ocorrência de um acidente, pois com eles, torna-se possível resfriar a água, mantendo a integridade do reator.

Toda árvore de falhas pode ser mapeada em uma rede bayesiana, Khakzad et al. (2011). Sendo assim, a árvore do CHRS foi mapeada e a rede em questão será utilizada neste trabalho. As Figuras 4.2 e 4.3, representam a árvore de falhas do CHRS, já a Figura 4.4, é a rede bayesiana mapeada da árvore do CHRS.

O diagrama do CHRS também é encontrado no Apêndice A, a árvore de falha, modelada no SAPHIRE e a rede modelada no netica, assim como as subárvores utilizadas estão localizadas no Apêndice B, as tabelas com valores a serem utilizados, no Apêndice C e, por fim, os resultados encontrados na modelagem tradicional, com a finalidade de se comparar a modelagem híbrida, encontram-se no Apêndice D.

Dentre os métodos analisados neste trabalho, será utilizado o de Monte Carlo, para propagar incertezas nas entradas da rede bayesiana e para o evento que envolve erro do operador, a propagação será realizada através da lógica *fuzzy*.

Ao analisar, na literatura, a abordagem híbrida *fuzzy*-bayesiana, nota-se que estas duas técnicas não são competidoras, elas se complementam. Elas modelam incertezas distintas. Enquanto a RB modela a incerteza aleatória (probabilidade), a lógica *fuzzy* modela a imprecisão (possibilidade), Tibiriçá (2005).

O objetivo de lidar com esta abordagem híbrida está na possibilidade de se modelar incertezas aleatória e/ou imprecisas para desenvolver sistemas especialistas. Esta abordagem híbrida permite tratar incertezas nas entradas da RB formadas por nós dicotômicos ou não. Estas variáveis de entrada, que possuem características de imprecisão, são fuzzyficadas gerando as probabilidades de saída da rede, Tibiriçá (2005).

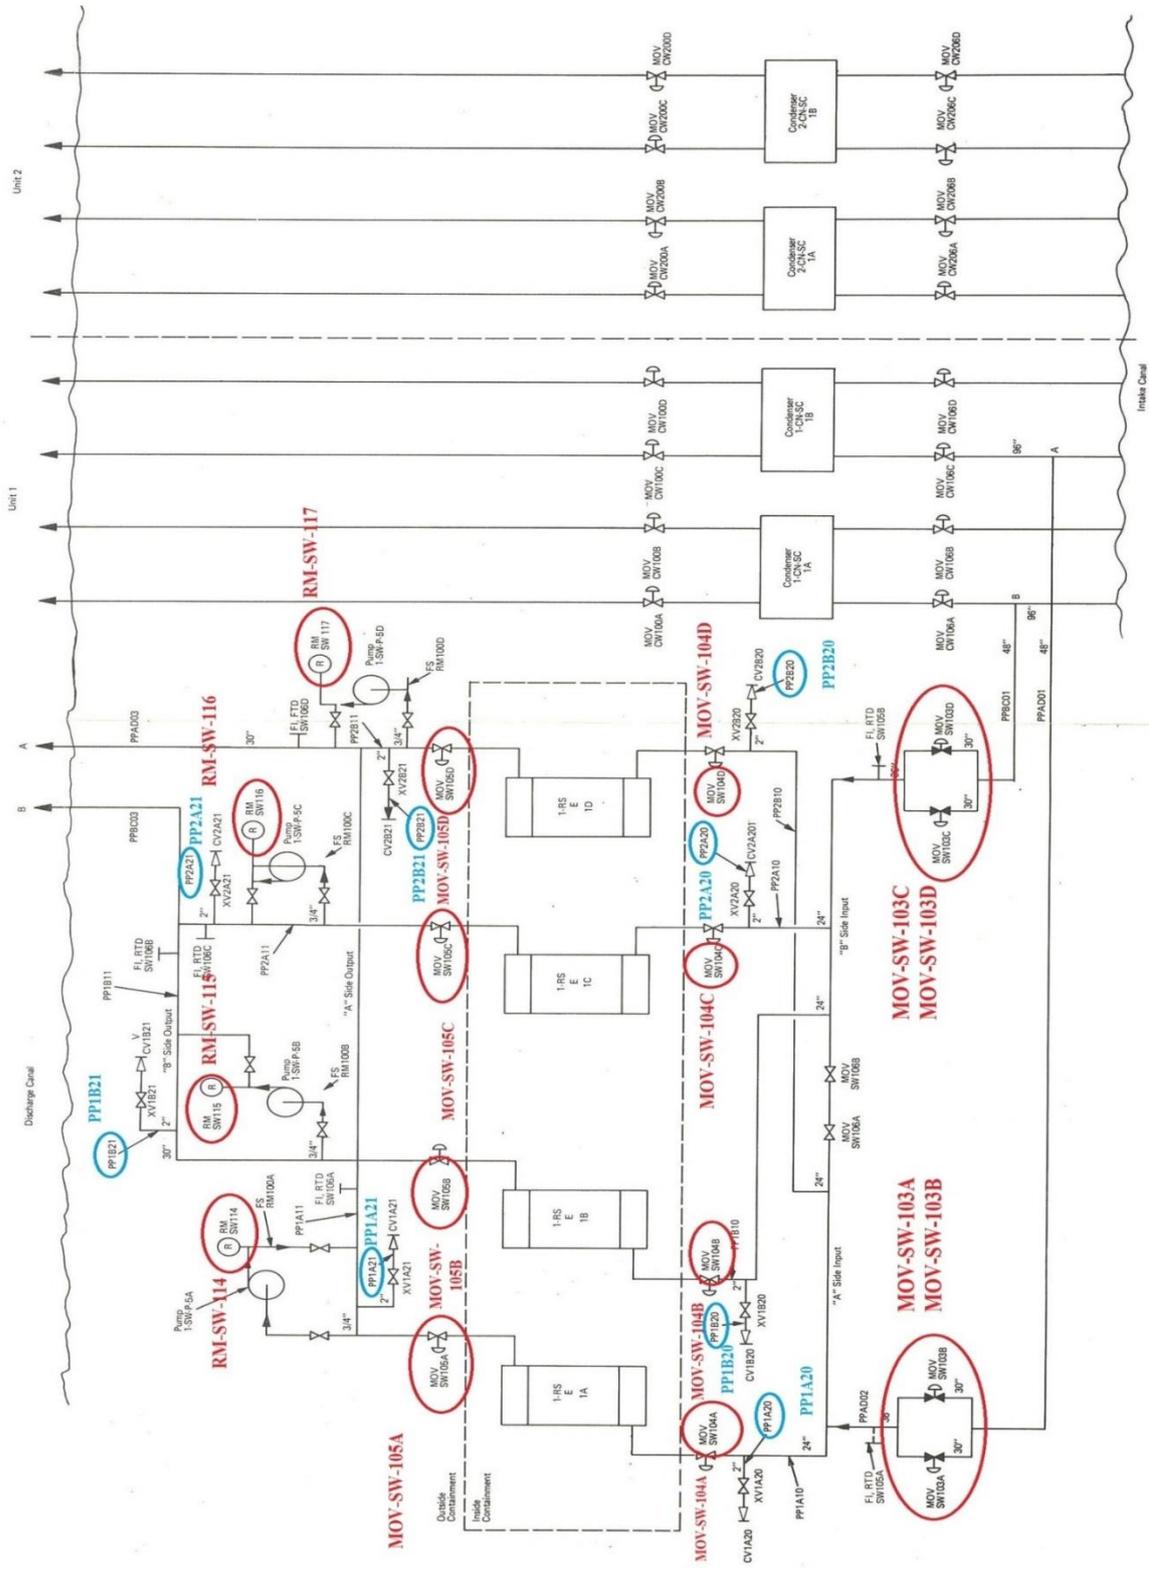


Figura 4.1: Diagrama de Fluxo Simplificado do CHRS, Estevão (2013).

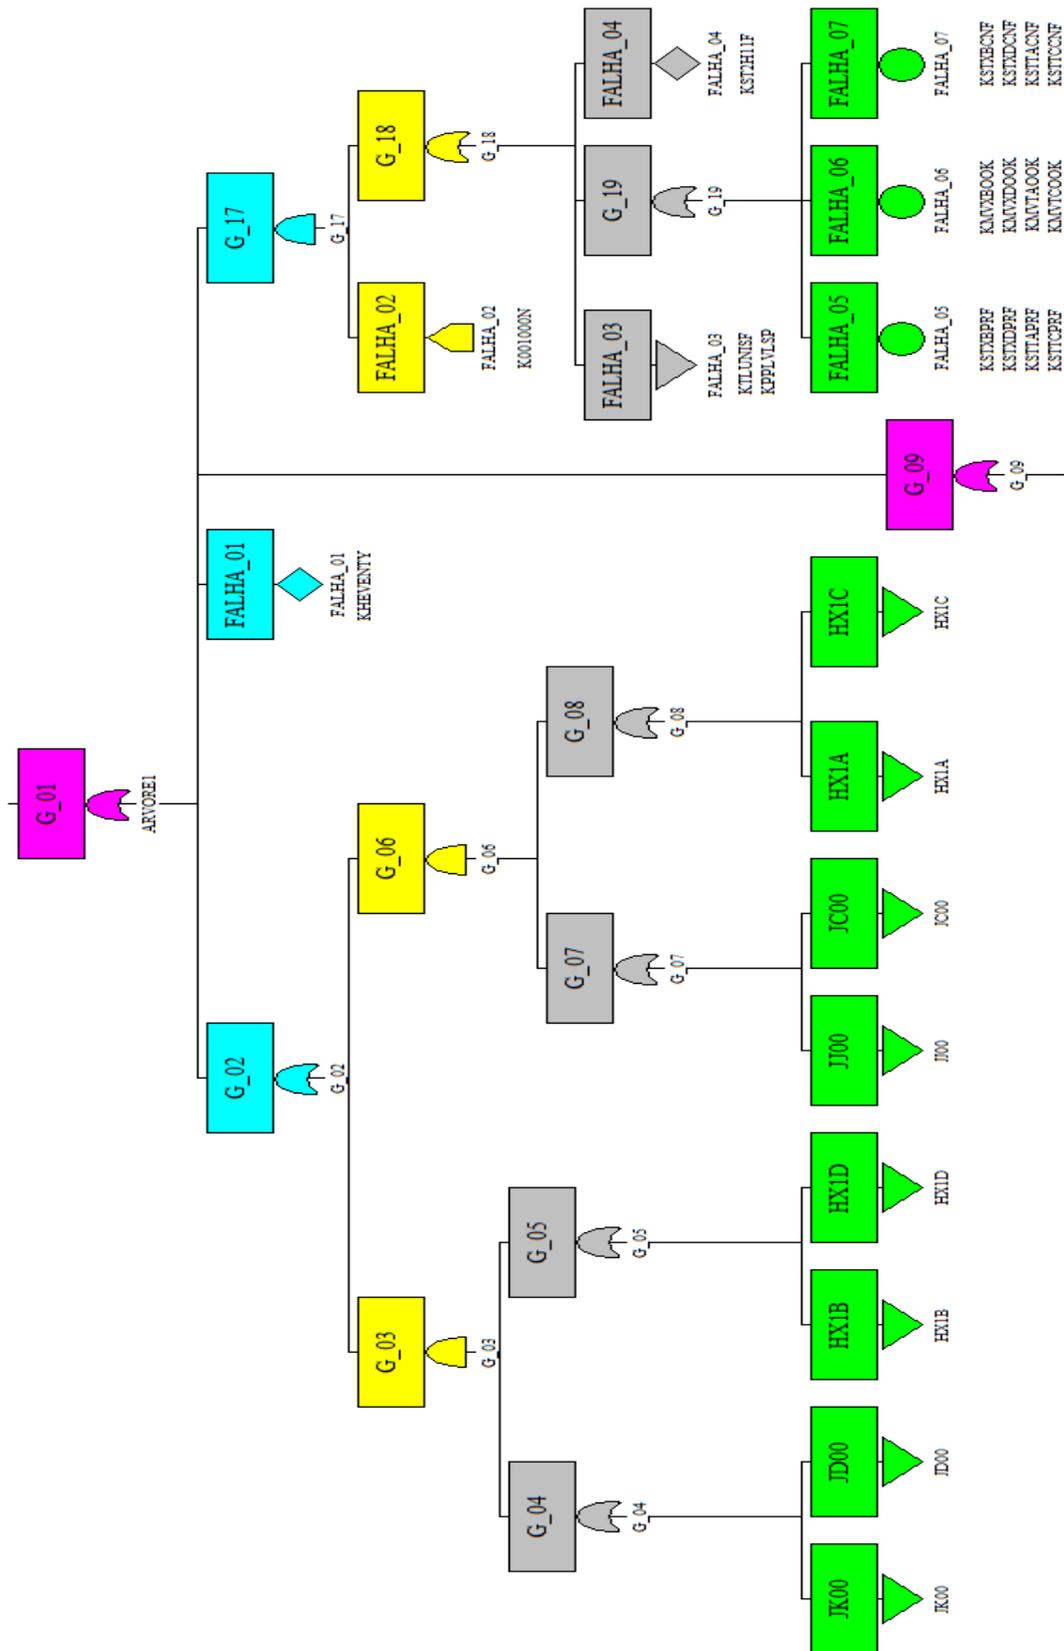


Figura 4.2: Árvore de Falha, modelada pelo SAPHIRE, do CHR5, Estevão (2013).

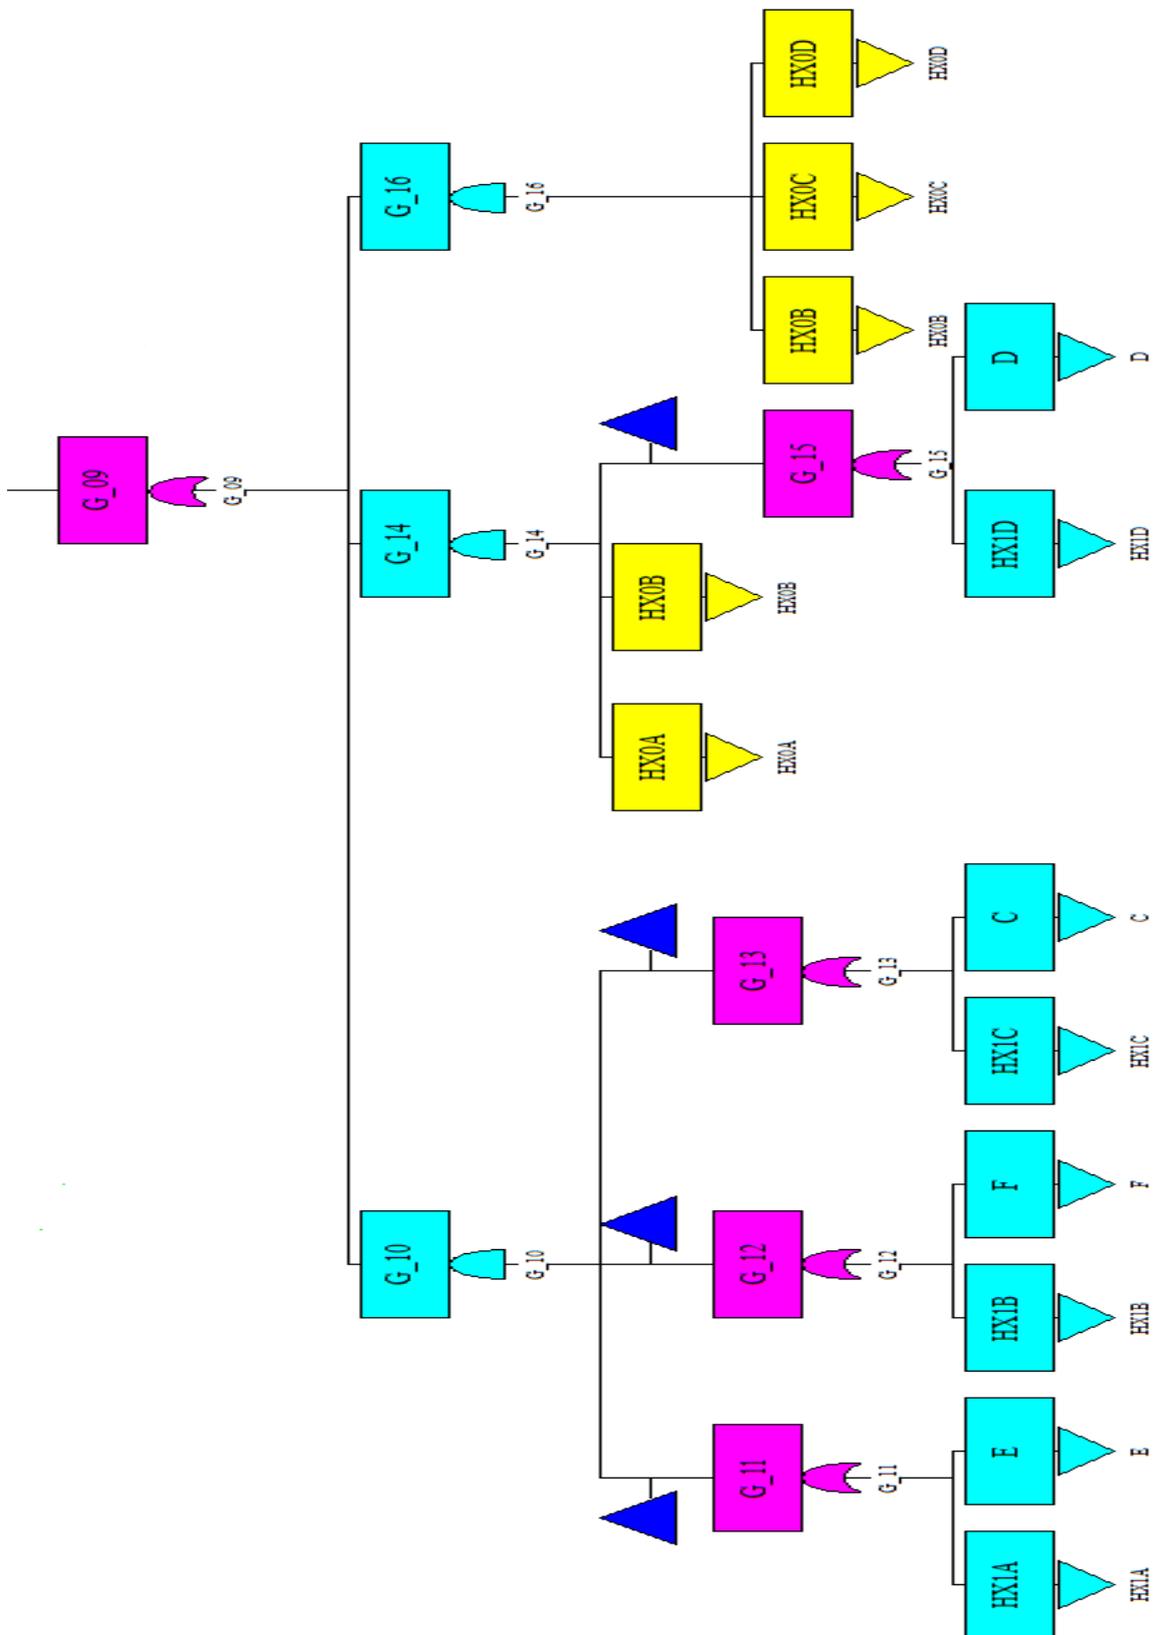


Figura 4.3: Continuação da árvore de falhas, do CHRS, Estevão (2013).

5 RESULTADOS

Conforme visto nos capítulos anteriores, a rede a ser utilizada será a do CHRS. A fim de propagar incertezas, por Monte Carlo, será utilizado um gerador de números aleatórios, que se encontra no FORTRAN (*formula translation system*), *call random_seed*. A Figura 5.1 resume, através de um fluxograma, a ordem de realização da modelagem.

A modelagem realizada considerou a lognormal, uma melhor opção dentre as distribuições, visando orientações feitas pelo WASH (1975). Segundo WASH (1975), uma das razões para o uso da lognormal, é os dados de entrada variarem por fatores, como por exemplo, a taxa de falha estimada em potência de 10. Outra razão, está na assimetria positiva da lognormal (explica a ocorrência de desvios menos prováveis, como taxa de falha anormalmente alta).

Além da mediana, também é possível encontrar, no WASH (1975), os valores de limites inferiores e superiores do nó a ser utilizado. A fim de limitar os valores propagados, foi utilizada a lognormal truncada, respeitando os limites acima citados.

A modelagem será feita pelo método de Monte Carlo, através da geração de números aleatórios, que seguem uma distribuição lognormal truncada, para aplicação nos nós da rede. Há um nó, que trata do erro do operador, nesta mesma rede, e ele será modelado por lógica *fuzzy*.

O erro do operador, envolve as aberturas de ventilação nos quatro caminhos do fluxo do trocador de calor, se as aberturas estiverem fechadas, o fluxo de água do refrigerante, através do trocador de calor, é inibido, WASH (1975).

A lógica fuzzy será utilizada, sem considerar as variáveis linguísticas, pois trata-se de um único nó. Sua utilização se deu para mostrar que é possível utilizar a lógica fuzzy, para a realização desta modelagem.

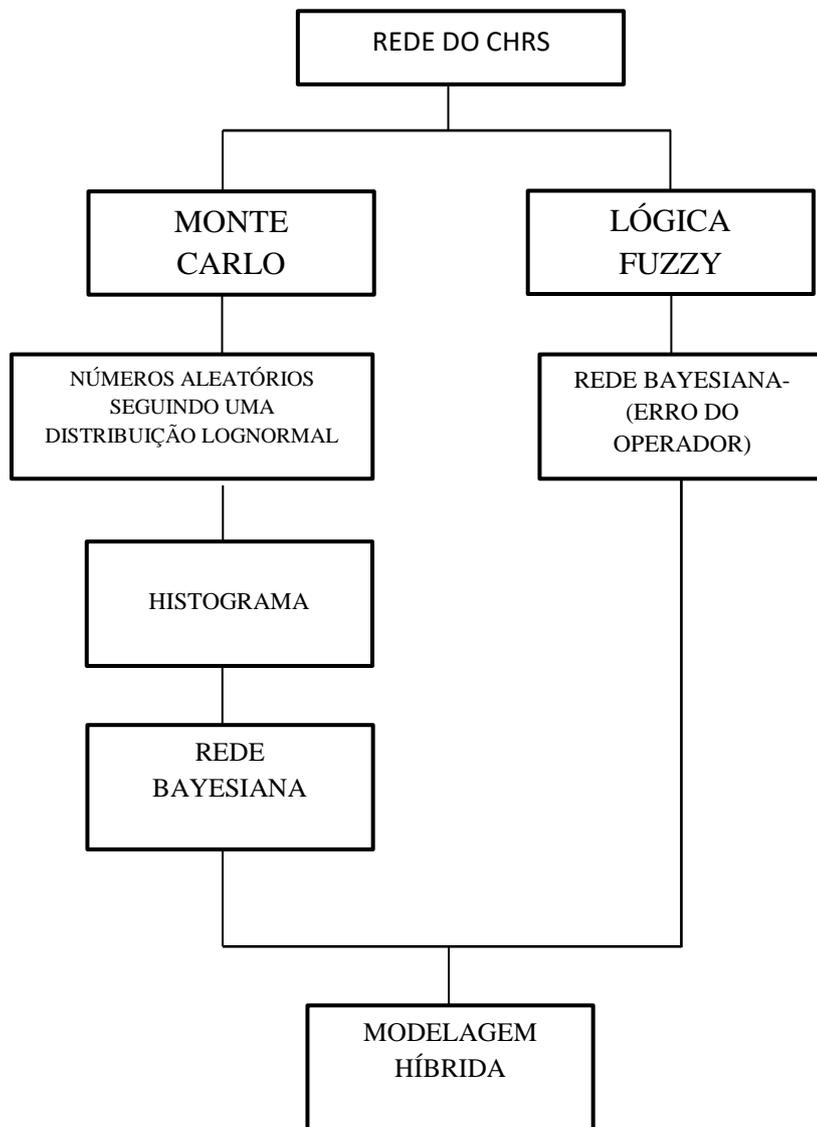


Figura 5.1 – Fluxograma da modelagem híbrida realizada

5.1 MODELAGEM PELO MÉTODO DE MONTE CARLO

Zaninetti (2017) demonstra as vantagens de se utilizar uma distribuição lognormal truncada esquerda e direita. Usando informações obtidas em Zaninetti (2017) e com uso de transformação inversa, pode-se concluir que a equação (5.1) calcula os valores da variável aleatória que segue uma distribuição lognormal truncada.

$$t = t_0 \exp \left\{ \omega \Phi^{-1} \left\{ \Phi \left(\frac{1}{\omega} \ln \frac{t_{min}}{t_0} \right) + \left[\Phi \left(\frac{1}{\omega} \ln \frac{t_{max}}{t_0} \right) - \Phi \left(\frac{1}{\omega} \ln \frac{t_{min}}{t_0} \right) \right] U \right\} \right\} \quad (5.1)$$

$$\omega = \frac{1}{1,645} \ln r \quad (5.2)$$

Onde,

t é o número gerado, que segue uma distribuição lognormal truncada;

t_0 é o valor da mediana da lognormal;

r é o fator erro;

t_{max} é o limite superior;

t_{min} é o limite inferior;

U é o número aleatório;

Com as equações acima, tornou-se possível a modelagem, através da linguagem de programação, para a propagação de incertezas, pelo método de Monte Carlo. A cada rodada, um número aleatório, entre [0,1], é substituído. Este procedimento pode ser feito n vezes. Quanto mais rodadas, menor o erro.

5.2 MODELAGEM POR LÓGICA FUZZY

Nesta seção será modelado o erro do operador, utilizando a lógica fuzzy, a fim de encontrar o valor da possibilidade de falha. O conceito de possibilidade de falha é aplicado para substituir a taxa de falha (probabilidade) na análise de árvore de falha, Liang e Wang (1993).

A possibilidade de falha pode ser definida por um número fuzzy no intervalo [0,1]. Neste trabalho, o número *fuzzy* triangular, definido no intervalo [0,1], será utilizado. A escolha do número *fuzzy* triangular ocorreu devido a sua simplicidade (indicação retirada da literatura), Cheng (1999).

Segundo Liang e Wang (1991), é possível estimar os limites, inferior e superior, através da Tabela 5.1:

Tabela 5.1 : Uma forma de estimar os limites, superior e inferior, para estimar a taxa de falha, Liang e Wang (1991)

Taxa de Falha (q)	Limite Inferior	Limite Superior
$0,01 \leq q$	$q/5$	$2q - 5q$
$0,001 < q < 0,01$	$q/3$	$3q$
$q \leq 0,001$	$q/10$	$10q$

Para o nó que será modelado, tem-se que a taxa de falha é dada por 10^{-5} , o que remete ao último caso da tabela. Assim, os limites inferior e superior são dados por 10^{-6} e 10^{-4} , respectivamente. Com isto, pode-se iniciar a etapa de *fuzzyficação*.

Conforme citado anteriormente, será utilizado o número fuzzy triangular, e a função de pertinência é dada por:

$$\mu_A(x) = \begin{cases} 0 & \text{for } x \leq a \\ \frac{x-a}{m-a} & \text{for } a < x \leq m \\ \frac{b-x}{b-m} & \text{for } m < x < b \\ 0 & \text{for } b \leq x \end{cases} \quad (5.3)$$

A Figura 5.2 representa a função de pertinência, onde A é um subconjunto *fuzzy* e X é o universo do discurso. A cada valor de X, obtém-se um respectivo valor para $\mu_A(x)$, ou seja,

$$A = \{(x, \mu_A(x)) / x \in X\}.$$

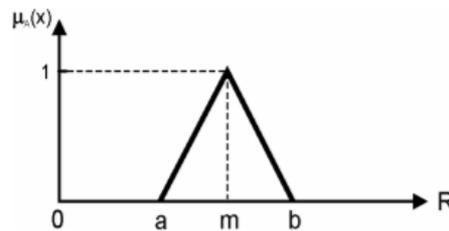


Figura 5.2: Função de Pertinência, Moré (2004).

Conforme citado anteriormente, os limites inferior e superior são dados por 10^{-6} e 10^{-4} , respectivamente. Assim, $a = 10^{-6}$, $m = 10^{-5}$ e $b = 10^{-4}$, valores que estão presentes na abscissa do gráfico. Entre os valores de a e m , serão considerados 15 pontos, esta quantidade foi considerada, a fim de se obter um valor aproximado da taxa de falha de entrada. Segue análogo os valores entre m e b .

A Tabela 5.2 mostra os valores de entrada para a abscissa e os respectivos graus de pertinência localizados nas ordenadas.

Tabela 5.2: Resultado da *fuzzyficação*

x	Membership Functions
0,000001	0
1,5625E-06	0,0625
0,000002125	0,125
2,6875E-06	0,1875
0,00000325	0,25
3,8125E-06	0,3125
0,000004375	0,375
4,9375E-06	0,4375
0,0000055	0,5
6,0625E-06	0,5625
0,000006625	0,625
7,1875E-06	0,6875
0,00000775	0,75
8,3125E-06	0,8125
0,000008875	0,875
9,4375E-06	0,9375
0,00001	1
0,000015625	0,9375
0,00002125	0,875
0,000026875	0,8125
0,0000325	0,75
0,000038125	0,6875
0,00004375	0,625
0,000049375	0,5625
0,000055	0,5
0,000060625	0,4375
0,00006625	0,375
0,000071875	0,3125
0,0000775	0,25
0,000083125	0,1875
0,00008875	0,125
0,000094375	0,0625
0,0001	0

O próximo passo a ser seguido é a defuzzyficação. Este processo pode ser definido como uma função que associa a cada conjunto fuzzy um elemento que o represente. O valor obtido após a defuzzyficação é considerado o valor esperado, traçando uma analogia com as distribuições de probabilidade, Moré (2004).

Existem alguns métodos muito utilizados para a defuzzyficação, porém o COG (*Center of Gravity*), é o mais utilizado, Moré (2004). Este método é dado pela equação 6.4:

$$COG = \frac{\sum_{x=a}^b \mu_A(x) \cdot x}{\sum_{x=a}^b \mu_A(x)} \quad (5.4)$$

Considerando os valores da Tabela 5.2 e utilizando o COG, o valor resultante é $2,34473 \times 10^{-5}$. Este valor foi inserido no nó, *falha_01*, da rede.

Para realizar a propagação de incertezas na rede bayesiana, também pode ser utilizado o software *Neticatm*. Este software permite a leitura de planilhas no Excel, o que possibilita a inserção dos valores da modelagem.

A escolha do número de simulações se justifica através da Tabela 5.3, que indica a média encontrada após cada rodada. Pode-se perceber que o valor é alterado infimamente. Por isso, serão considerados 13000 simulações. Este número é o que mais se aproxima do valor real e possui o menor custo computacional.

Tabela 5.3: Médias encontradas após as simulações

NÚMERO DE SIMULAÇÕES	MÉDIA
5000	$4,66 \times 10^{-5}$
6000	$4,66 \times 10^{-5}$
7000	$4,66 \times 10^{-5}$
10000	$4,66 \times 10^{-5}$
12000	$4,66 \times 10^{-5}$
13000	$4,67 \times 10^{-5}$
15000	$4,67 \times 10^{-5}$
18000	$4,67 \times 10^{-5}$
20000	$4,67 \times 10^{-5}$
22000	$4,67 \times 10^{-5}$
28000	$4,67 \times 10^{-5}$
30000	$4,67 \times 10^{-5}$
80000	$4,67 \times 10^{-5}$
90000	$4,67 \times 10^{-5}$
100000	$4,67 \times 10^{-5}$

A Figura 5.3 indica a modelagem híbrida, realizada com o uso do método de Monte Carlo e lógica fuzzy, para a propagação de incertezas da rede do sistema de remoção de calor da contenção (CHRS). O valor médio encontrado após a simulação é de

$4,67 \times 10^{-5}$ e o desvio padrão é $8,38482 \times 10^{-6}$. Os valores encontrados são compatíveis com os valores obtidos na modelagem realizada através de redes bayesianas para o mesmo problema, Apêndice B, Figura B.2.

Vale ressaltar que o intervalo de dados encontrados na parte inferior da Figura 5.3, são os resultados da simulação. No topo dos retângulos há o quantitativo de elementos que caem dentro do intervalo mencionado.



Figura 5.3: Modelagem híbrida para a propagação de incertezas.

6 CONCLUSÃO E RECOMENDAÇÕES

Após a ocorrência de acidentes de grande proporção, como foi o caso de Fukushima, a comunidade nuclear concentra estudos em formas que auxiliem na contenção de um acidente.

O sistema de remoção de calor da contenção (CHRS) em conjunto com o sistema de recirculação do spray da contenção (CSRS), disponibilizam meios para remover o calor do poço da contenção, mediante a ocorrência de um acidente de perda de refrigerante (LOCA).

Neste trabalho, foi desenvolvida a propagação de incertezas em redes bayesianas no âmbito de análises probabilísticas de segurança de centrais nucleares (para o cálculo de indisponibilidades de sistemas de segurança da central) . Esta propagação foi realizada com o uso da rede bayesiana do (CHRS). Para o cálculo, o método de Monte Carlo e a lógica fuzzy, foram utilizados.

Conforme destacado na literatura, o método de Monte Carlo é eficiente para a propagação de incertezas, assim como a lógica fuzzy, Messeti e Queiroz (2002) e Liang e Wang (1991).

A principal vantagem de se utilizar a lógica *fuzzy*, deve-se a sua capacidade de lidar com incertezas. O uso do número *fuzzy* triangular é muito eficiente para representar a possibilidade de falha do evento básico sobre o ambiente *fuzzy*, Liang e Wang (1991). Este método substitui as probabilidades, passando a trabalhar com possibilidades, Moré (2004).

O método de Monte Carlo e a lógica fuzzy foram juntamente utilizados em uma modelagem híbrida, que permitiu considerar problemas com dados escassos e assim realizar as simulações necessárias. Através do resultado encontrado, pôde-se garantir a eficiência do método.

Recomenda-se, para trabalhos futuros, a utilização da opinião de especialistas, para a adesão dos dados de entrada, nesta modelagem híbrida. Isto pode ser realizado, com a aplicação de um formulário, que contenha perguntas inerentes ao trabalho em questão. Após a obtenção dos dados, trata-se os valores, estatisticamente, para servir de entrada, taxas de falha.

Portanto, é possível concluir, através dos resultados encontrados, que esta modelagem híbrida, é capaz de calcular, mesmo com dados escassos, a propagação de incertezas em redes bayesianas, tratando elementos com lógica booleana e também com lógica *fuzzy*.

REFERÊNCIAS BIBLIOGRÁFICAS

Amendola, A., Uncertainties in Systems Reliability Modelling: Insight Gained Through European Benchmark Exercises, Nuclear Engineering and Design, Vol. 93, pp. 215–225, 1986.

Barabalho, V., M., S., Sistemas Baseados em Conhecimento e Lógica Difusa para Simulação do Processo Chuva-Vazão, Tese de Doutorado, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2001.

Barber, D., Bayesian Reasoning and Machine Learning, University College London, Draft, 2010.

Barrio, R., Rodríguez, M., Abad, A., Serrano, S., Uncertainty Propagation or Box Propagation, Mathematical and Computer Modelling, vol. 54, pp. 2602 – 2615, 2011.

Bastos, R., L., Proposição de Testes Bootstrap para o Índice de Qualidade Sensorial, Dissertação de Mestrado, Universidade Federal de Lavras, Minas Gerais, 2013.

Benck, L., C., Wong, K., Candido, T., Distribuição de Weibull Conceitos Básicos Aplicações, Escola Superior de Engenharia e Gestão, São Paulo, 2008.

Bobbio, A., Ciancamerla, E., Minichino, M., Portinale, L., Improving the Analysis of Dependable Systems by Mapping Fault Trees into Bayesian networks”, *Reliability Engineering and System Safety*, vol. 71, pp. 249 – 260, 2001.

Cecon, P., R. e Silva, A., R., Introdução à metodologia de superfície de resposta, Apostila de Estudo, Viçosa, 2011.

Cheng, L., Y., Application of Monte Carlo Method for Operations of fuzzy numbers (in Portuguese), Brazilian Symposium on Intelligent Automation, São Paulo, 1999.

Correa, S., M., B., B., Probabilidade e Estatística, Minas Gerais, 2º edição, 2003.

Estevão, L. B., Estudo da Indisponibilidade de um Sistema de Segurança de uma Central Nuclear a Água Leve por Redes Bayesianas, Dissertação de Mestrado, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2013.

Efron, B., Bootstrap methods: Another look at the jackknife, *Ann. Statist* 7, 1-26, 1979.

Gomes, E. C., Análise de confiabilidade humana de procedimentos de radioterapia via redes bayesianas, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2011.

Guimarães, A., C., F., Uma Metodologia para Análise de Confiabilidade Baseada em Árvores de Falhas e Lógica Fuzzy, Tese de Doutorado, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 1997.

Guimarães, A., C., F. e Ebecken, N., F., F., FuzzyFTA: a fuzzy fault tree system for uncertainty analysis, *Annals of Nuclear Energy*, 26, PP 523-532, 1999.

Guimarães, A., C., F. e Lapa, C., M., F., Fuzzy Inference System for Evaluating and Improving Nuclear Power Plant Operating Performance, *Annals of Nuclear Energy*, 31, PP 311-322, 2004.

Guimarães, A., Lapa, C., M., F., Filho, F., F., L., S., F., Cabral, D., C., Fuzzy uncertainty modeling applied to AP1000 nuclear Power plant LOCA, *Annals of Nuclear Energy*, 38, PP 1775-1786, 2011.

Henley, E. J., Kumamoto, H., Reliability Engineering and Risk Assessment, Prentice Hall, Englewood Cliff, N, 1981

Jahani, E., Muhanna, R., L., Shayanfar, M., A., Barkhordari, M., A., Reliability Assessment with Fuzzy Random Variable Using Interval Monte Carlo Simulation, *Computer Aided Civil and Infrastructure Engineering*, vol. 29, PP 208-220, 2014.

Jané, D. A., Uma Introdução ao Estudo da Lógica Fuzzy, *Revista de Humanidades e Ciências Sociais Aplicadas*, Ourinhos, São Paulo, N° 02, 2004.

Jensen, F. V., *Bayesian Networks and Decision Graphs*, New York, Springer, 2001.

Jones, B. & Jenkinson, I. & Yang, Z. & Wang, J., 2010, The use of Bayesian network modelling for maintenance planning in a manufacturing industry, *Reliability Engineering and System Safety*, Elsevier, vol. 95(3), pages 267-277.

Khakzad, N., Khan, F., Amyotte, P., Safety Analysis in Process Facilities: Comparison of Fault Tree and Bayesian Network Approaches, *Reliability Engineering and System Safety*, vol. 96, PP. 925-932, 2011.

Liang, G., S., Wang, M., J., J., Fuzzy Fault-Tree Analysis Using Failure Possibility, *Microelectron Reliab.*, Vol. 33, No. 4, pp. 583-597, 1993.

Lima, G., S., Seleção de áreas para implantação de aterros sanitários: uma proposta baseada na análise do valor e lógica *fuzzy*, Tese de doutorado, COPPE, UFRJ, 1999.

Macedo, R. G., Análise de Propagação de Incertezas em Método de Estimação de Rigidez Estática por Dados Dinâmicos, Dissertação de Mestrado, Universidade Estadual de Campinas, Campinas, São Paulo, 2010.

Maletta, B. V., Modelos baseados em simulação de Monte Carlo: soluções para o cálculo do *Value-at-Risk.*, Dissertação de Mestrado, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2005.

Martins, V., L., M., Werner., L., Pinto, F., T., Uso da Simulação de Monte Carlo para Avaliação da Confiabilidade de um Produto, SIMPOI, Universidade Federal do Rio Grande do Sul, Rio Grande do Sul, 2010.

Martins, C., B., Metanálise caso a caso sob a perspectiva bayesiana, Tese de doutorado, Universidade de São Paulo, São Paulo, 2013.

Mckay, M. D., Beckman, R. J., Conover, W.J. A Comparison of Three Methods for Selecting Values of Input Variables in the Analysis of Output from a Computer Code *Technometrics*, 21:239-245, 1979.

Messetti, A. V., L., Queiroz, S. C., Método de Monte Carlo. Técnica de Redução da Variância, Universidade Estadual de Londrina, V.1, n.1, p. 39-44, 2002.

Modarres, M., Risk Analysis in Engineering, Techniques, Tools and Trends, Taylor e Francis, Boca Raton, 2006.

Montgomery, D. C. e Runger, G. C., Applied Statistics and Probability for Engineers, Terceira Edição, Wiley, New York, 1999.

Moré, J.D. Aplicação da lógica Fuzzy na avaliação da confiabilidade humana nos ensaios não destrutivos por ultra-som. Tese de Doutorado submetida ao programa de pós-graduação de Engenharia Metalúrgica e dos Materiais da Universidade Federal do Rio de Janeiro, COPPE, 2004.

Norsys Software Corp (2018), *Netica Tutorial*, Disponível < https://www.norsys.com/tutorials/netica/nt_toc_A.htm > Acesso em 20 de março de 2018.

Papaioannou, I., Betz, W., Zwirgmaier, K., Straub, D., MCMC algorithms for Subset Simulation, 41: 89-103, 2015.

Ribeiro, A., C., Sousa, A., L., Duarte, J., P., Frutuoso e Melo, P., F., Human Reliability Analysis of the Tokai-Mura Accident through a THERP-CREAM and Expert Opinion Auditing Approach, Safety Science, V. 87, PP- 269-279, 2016.

Rochman C. M., Hoh E., Kurobe T. & Teh S. J. Ingested plastic transfers hazardous chemicals to fish and induces hepatic stress. Sci. Rep. 3, 3263 (2013).

Rocquigny, E., Devictor, N., Tarantola, S., "Uncertainty in Industrial Practice, A Guide to Quantitative Uncertainty Management", England, 2008.

Sastry, S.I., Uncertainty Analysis of Transport-Transformation Models, Tese de Doutorado, Rutgers, The State University of New Jersey", New Brunswick, New Jersey, 1999.

Saliby, E. A reappraisal of some simulation fundamentals. 1980. Tese de Doutorado - University of Lancaster, 1980.

Sallaberry, C. J., Helton, J. C., Hora, S. C., Extension of Latin Hypercube Samples with Correlated Variables, *Reliability Engineering and System Safety* 93: 1047 – 1059, 2007.

Simões Filho, S., Análise de Árvore de Falhas Considerando Incertezas na Definição dos Eventos Básicos, Tese de Doutorado, COPPE/UFRJ, Rio de Janeiro, 2006.

Shooman, M., L., Probabilistic Reliability: an engineering approach, Second Edition, Malabar, Florida, 1990.

Tibiriçá, C., A., G., Uma Abordagem Híbrida Fuzzy-Bayesiana para Modelagem de Incertezas, Dissertação de Mestrado, Universidade Federal de Santa Catarina, Florianópolis, 2005.

Vieira, W., J., Uma contribuição para a utilização da amostragem por importância em cálculos de Monte Carlo, IX Simpósio de Logística e Pesquisa Operacional da Marinha – SALIBY, E., A Reappraisal of Some Simulation Fundamentals, University of Lancaster, 2006.

WASH-1400 (NUREG 75/014), Reactor Safety Study, US Nuclear Regulatory Commission, Washington DC, Outubro 1975.

Werner, L., Martins, V., L., M., Bigueline, C., B., Aplicação da Simulação de Monte Carlo para Modelagem do Volume Total de um Cosmético, XXXI Encontro Nacional de Engenharia de Produção, Belo Horizonte, 2011.

Yoriyaz, H., Monte Carlo Method: principles and applications in Medical Physics (in Portuguese), *Brazilian journal of medical physics*, São Paulo, 2009.

Zadeh, L., Fuzzy Sets, *Journal Information and Control*, Berkeley, 1965.

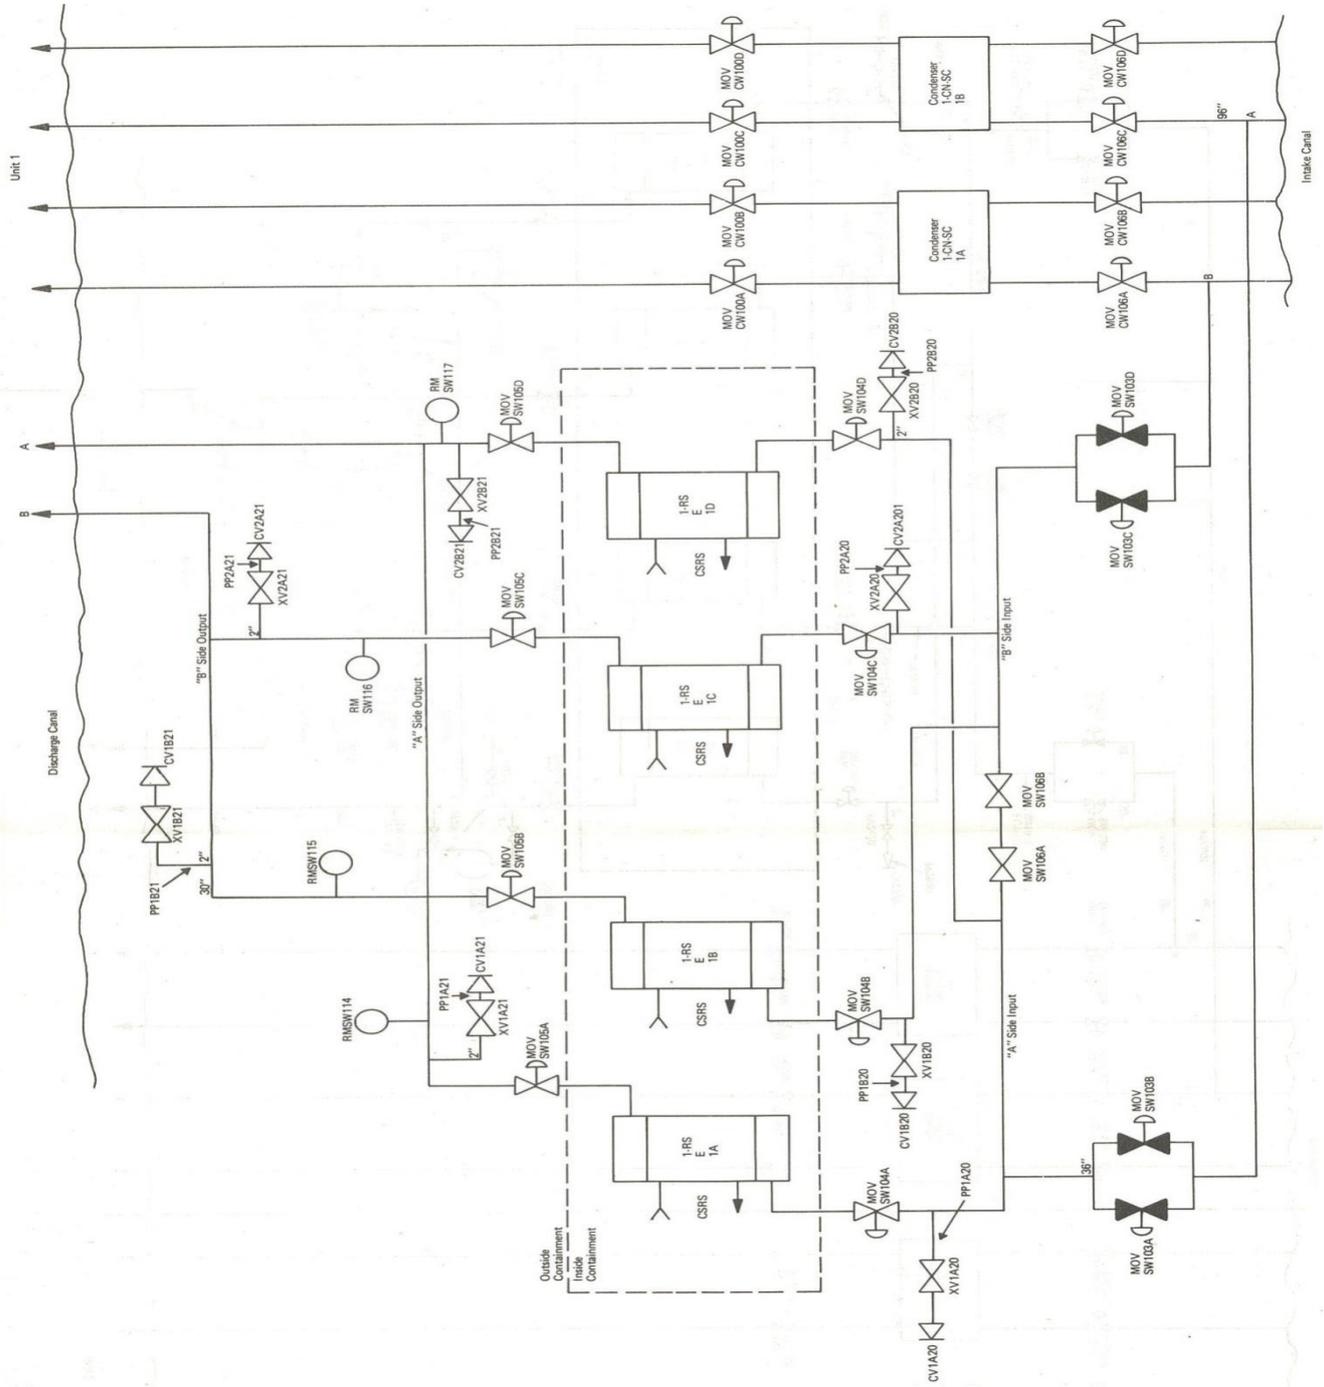
Zaninetti, L., A left and right truncated lognormal distribution for the stars, Physics Department, I-10125, Italy, 2017.

Zhao, Y.; Ono, T. A general procedure for first/second-order reliability method (FORM/SORM), Structural Safety, Amsterdam, v. 21, p.95-112, 1999.

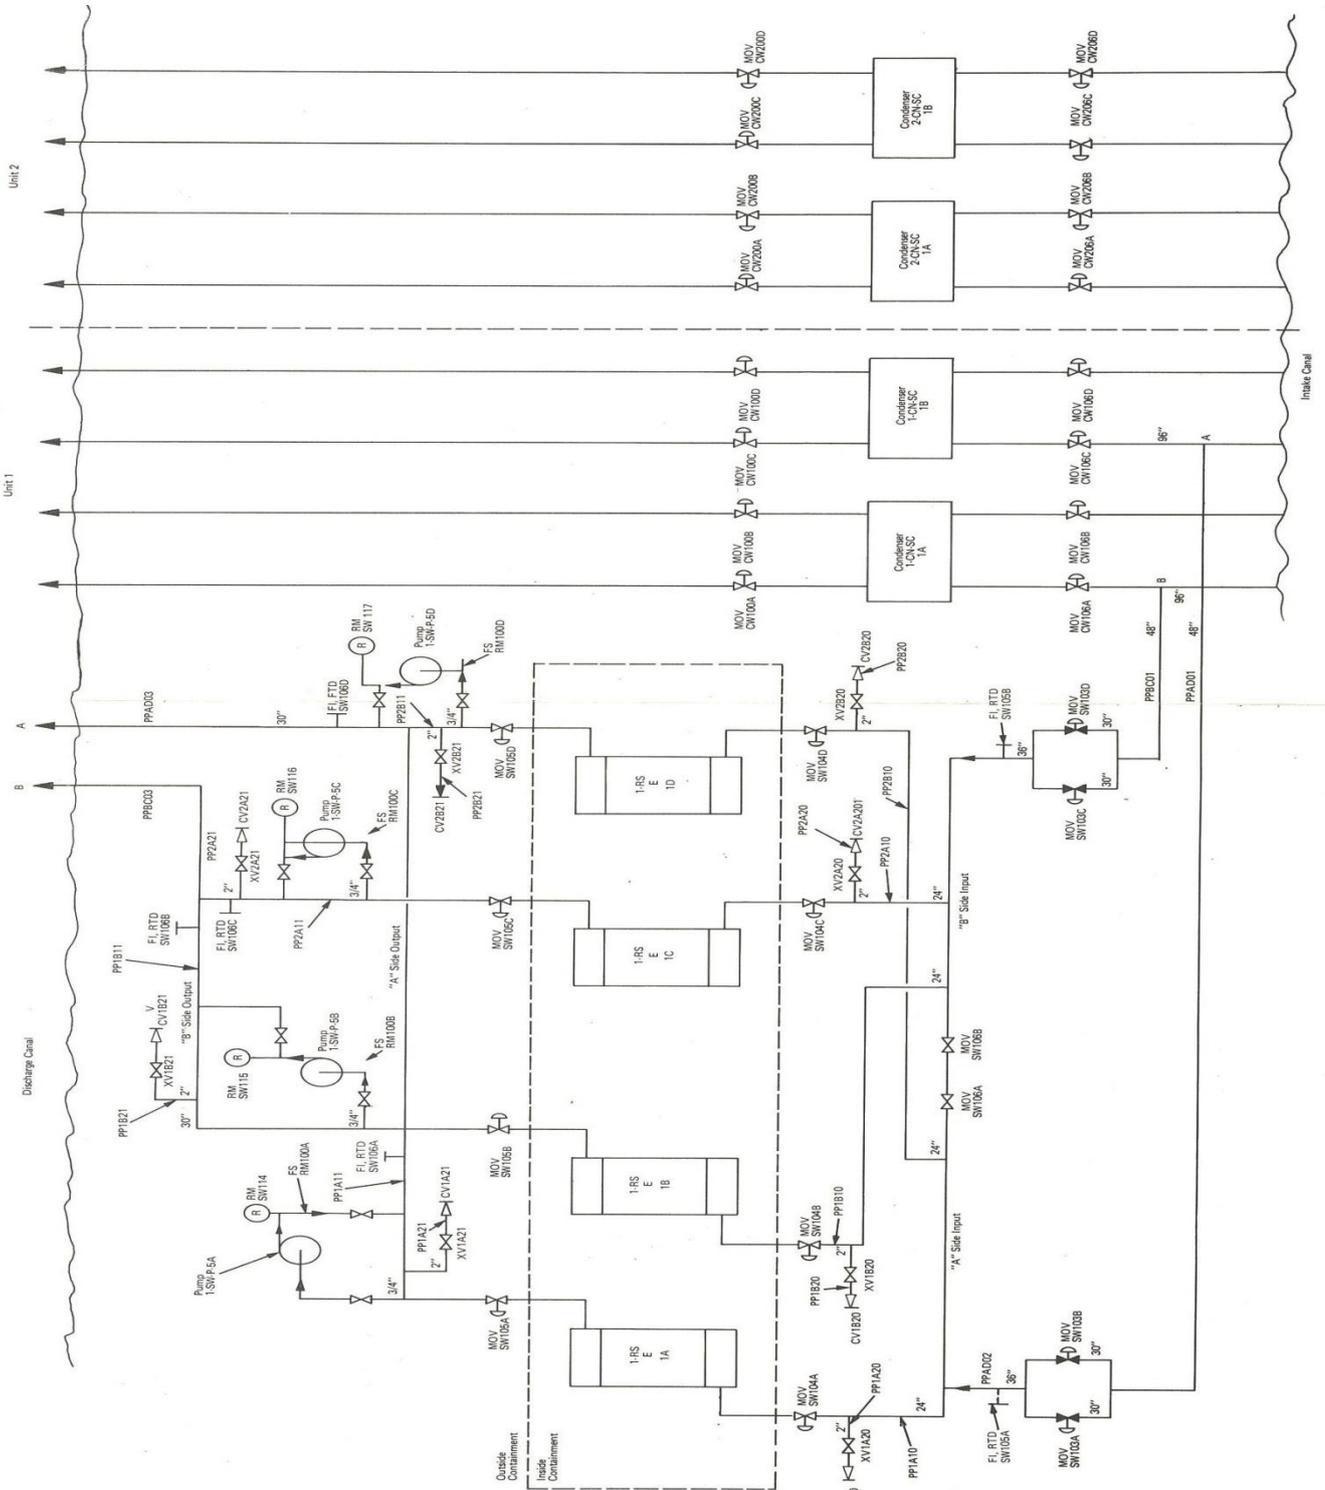
Zonouz, S., A., Miremadi, S., G., A Fuzzy-Monte Carlo Simulation Approach for Fault Tree Analysis, Sharif University of Technology, Iran, 2006.

APÊNDICE A – DIAGRAMAS DO SISTEMA DE REMOÇÃO DE CALOR DA CONTENÇÃO

A.1 DIAGRAMAS DE FLUXO SIMPLIFICADO DO CHRS

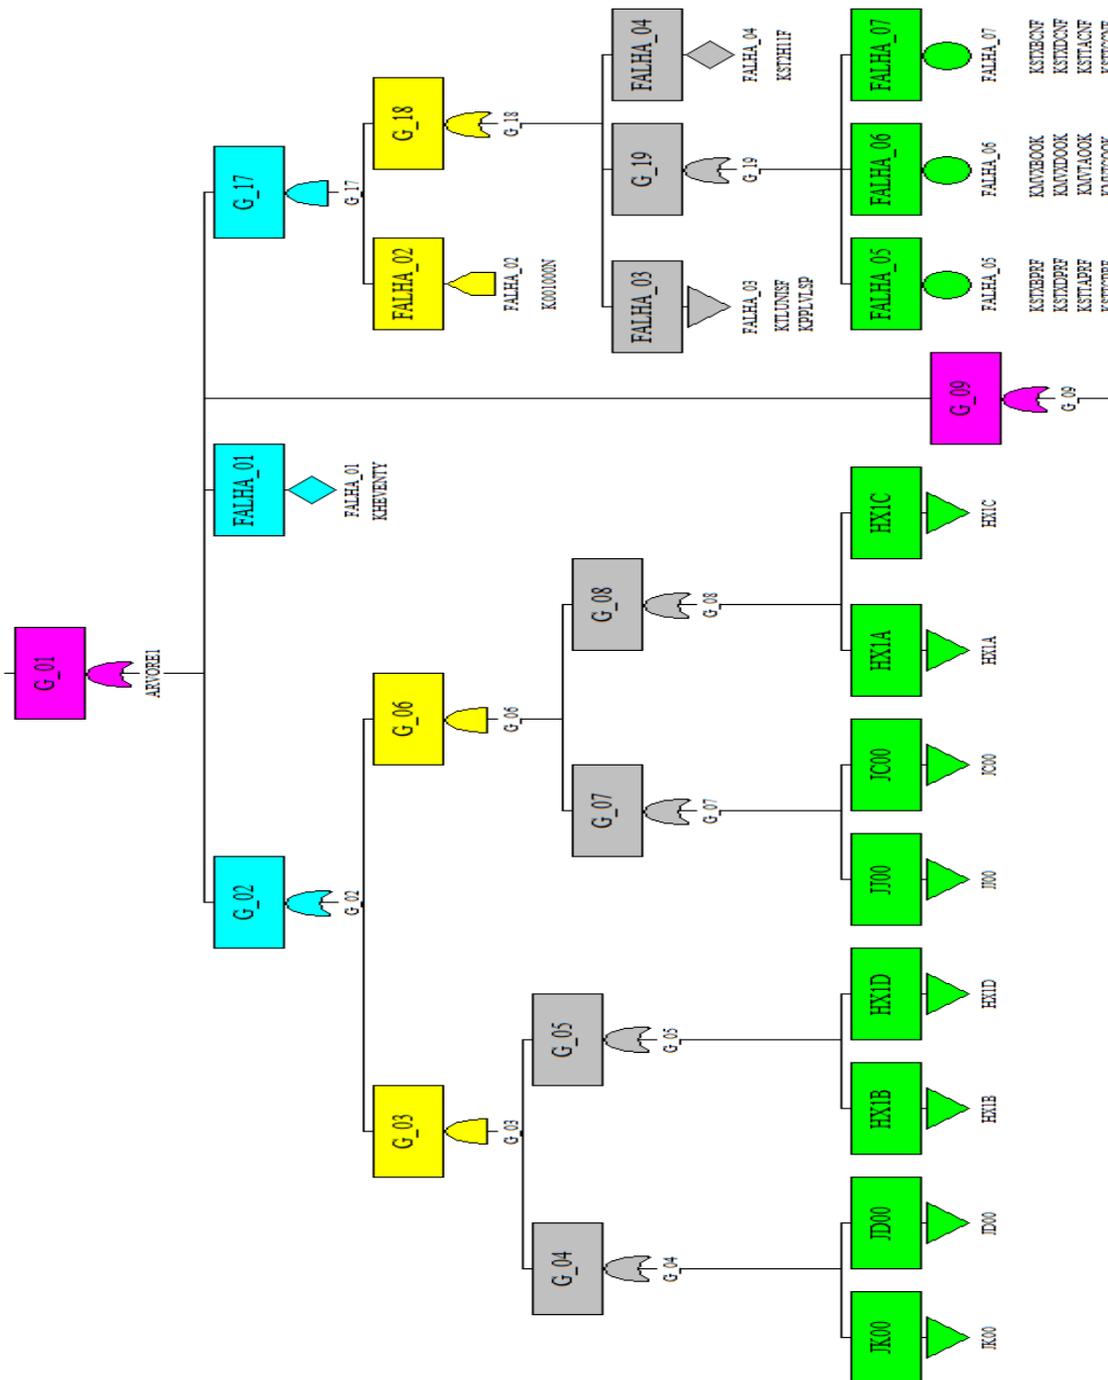


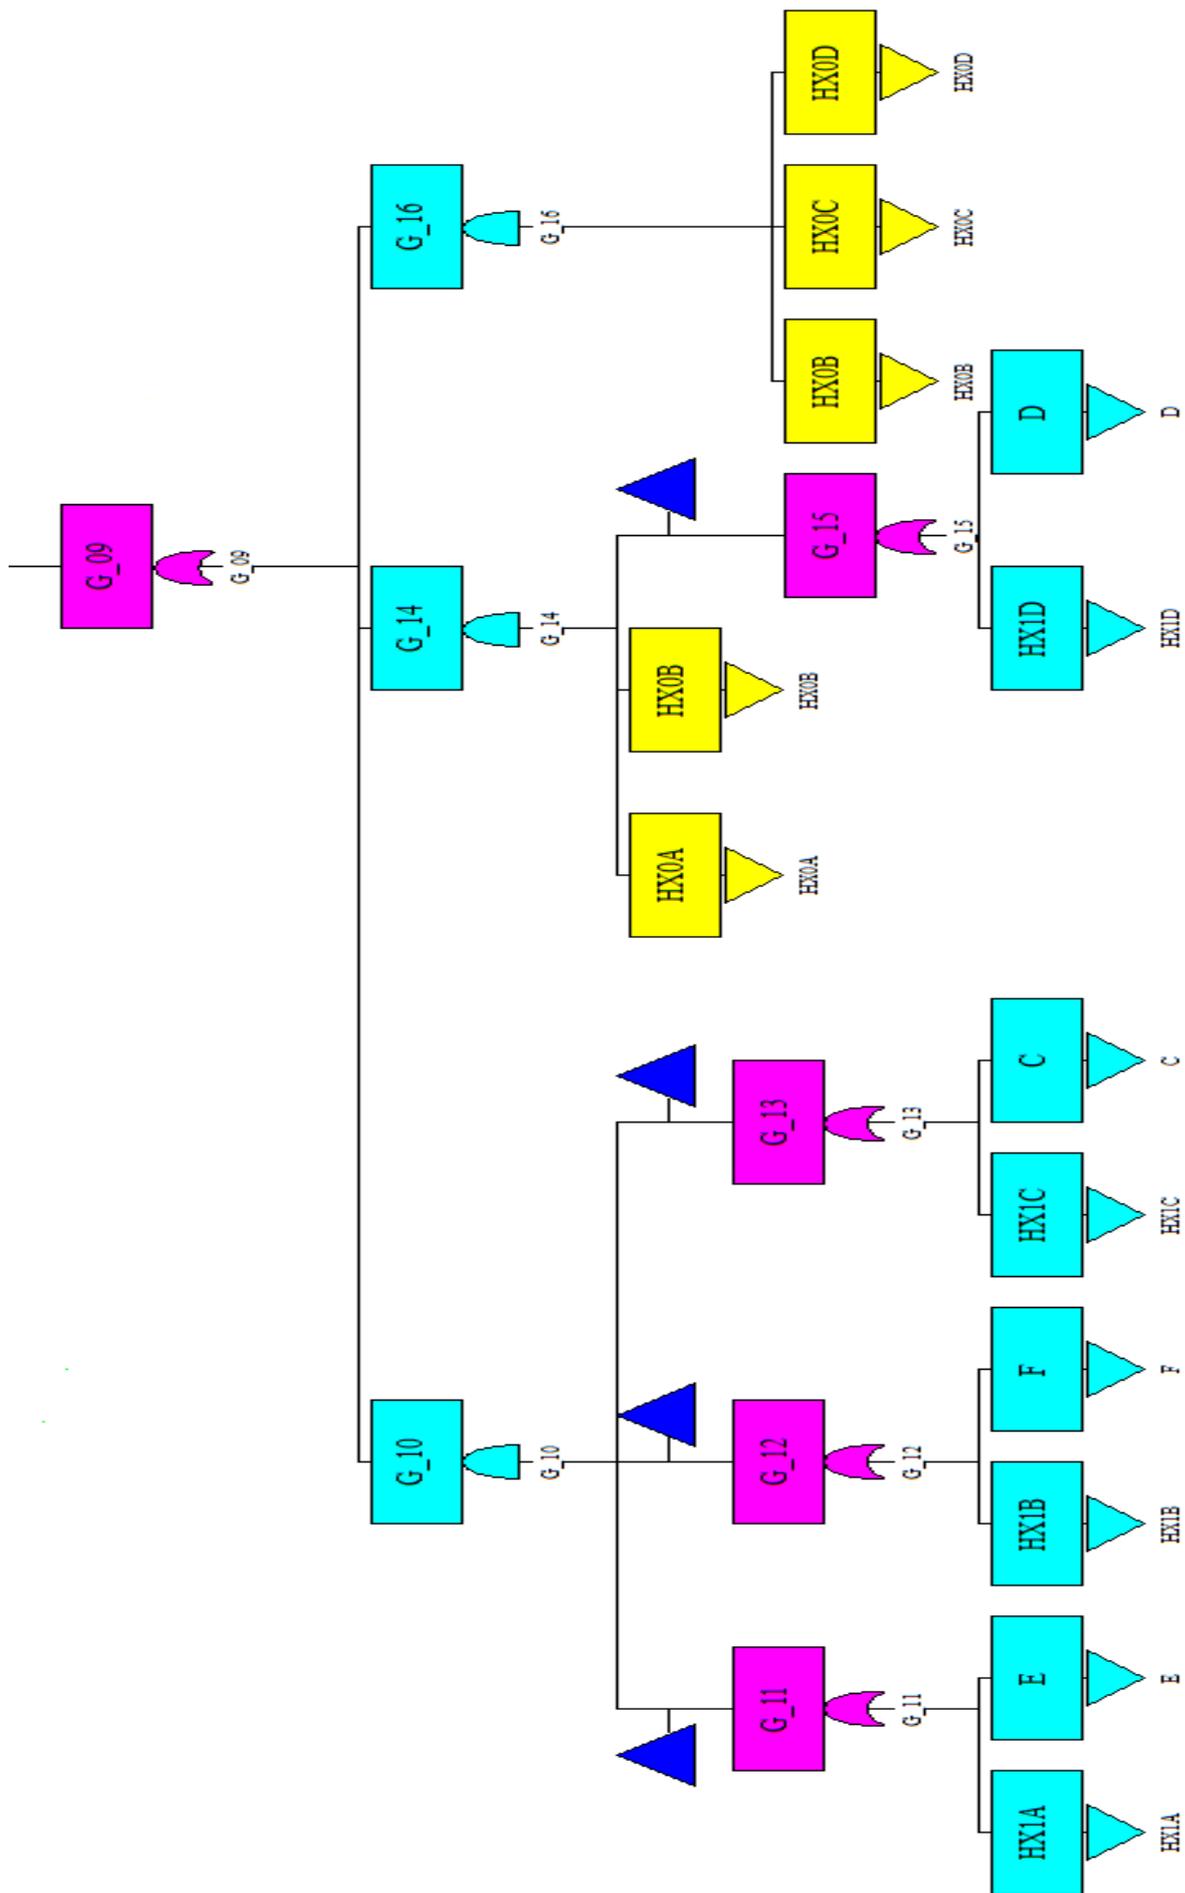
A.2 DIAGRAMAS DE FLUXO SIMPLIFICADO DO CHRS



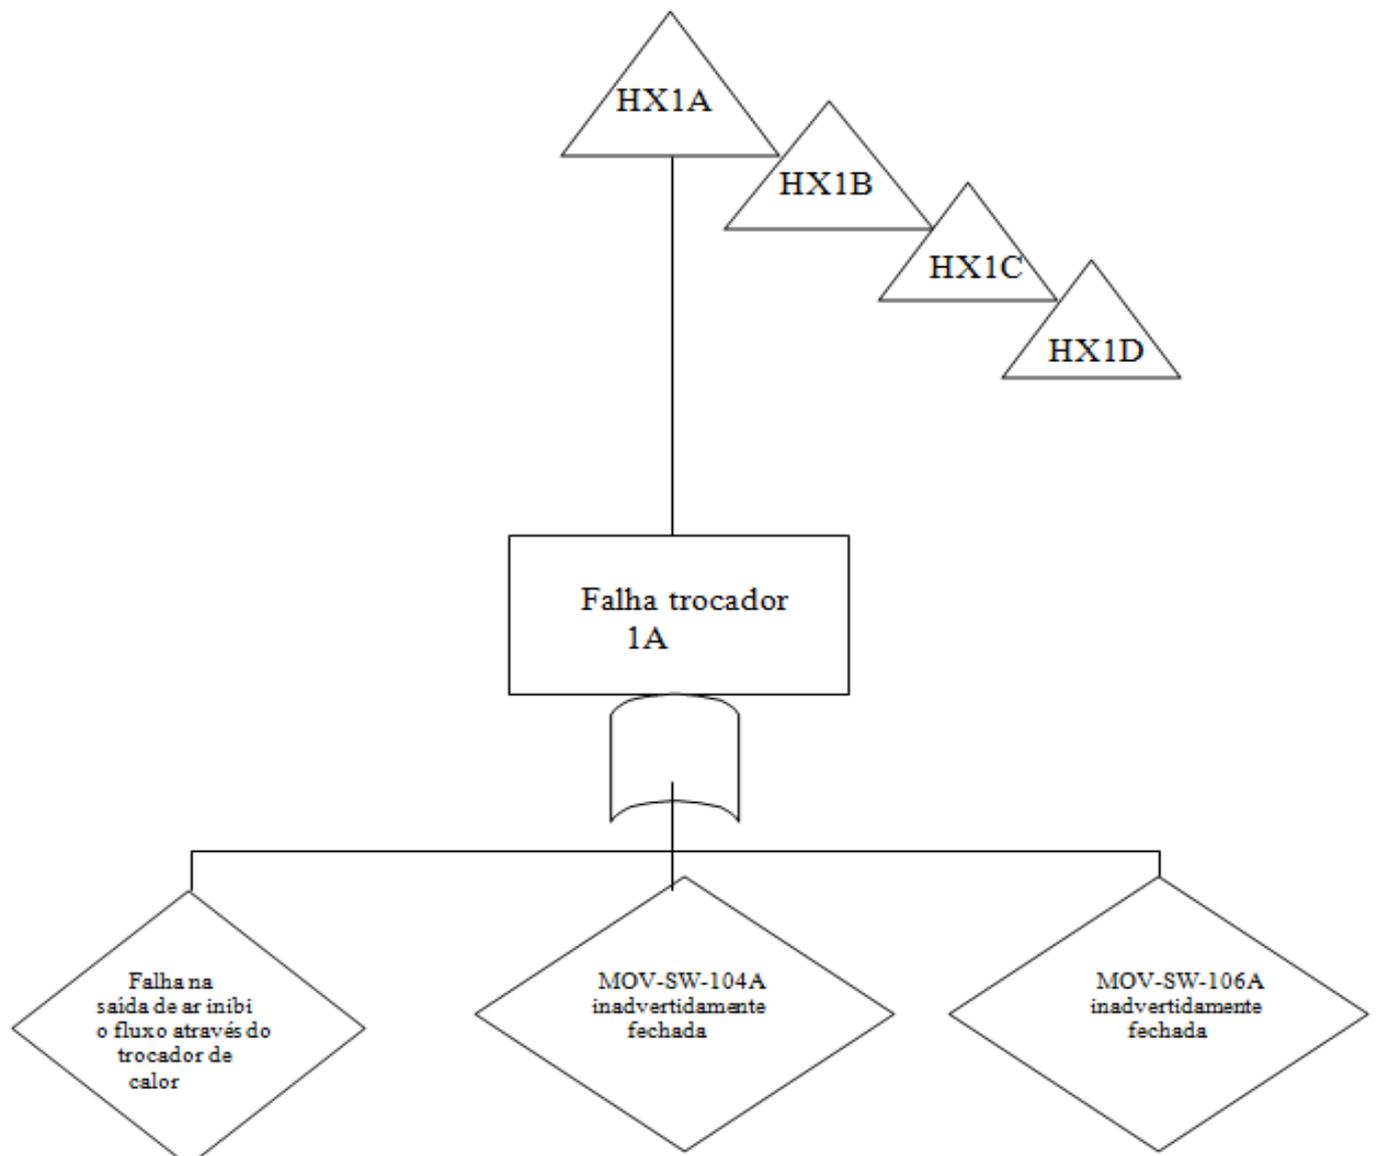
APÊNDICE B – ÁRVORE DE FALHAS DO CHRS REPRODUZIDA NO SAPHIREE REDE BAYESIANA REPRODUZIDA NO NETICA

B.1 ÁRVORE DE FALHAS



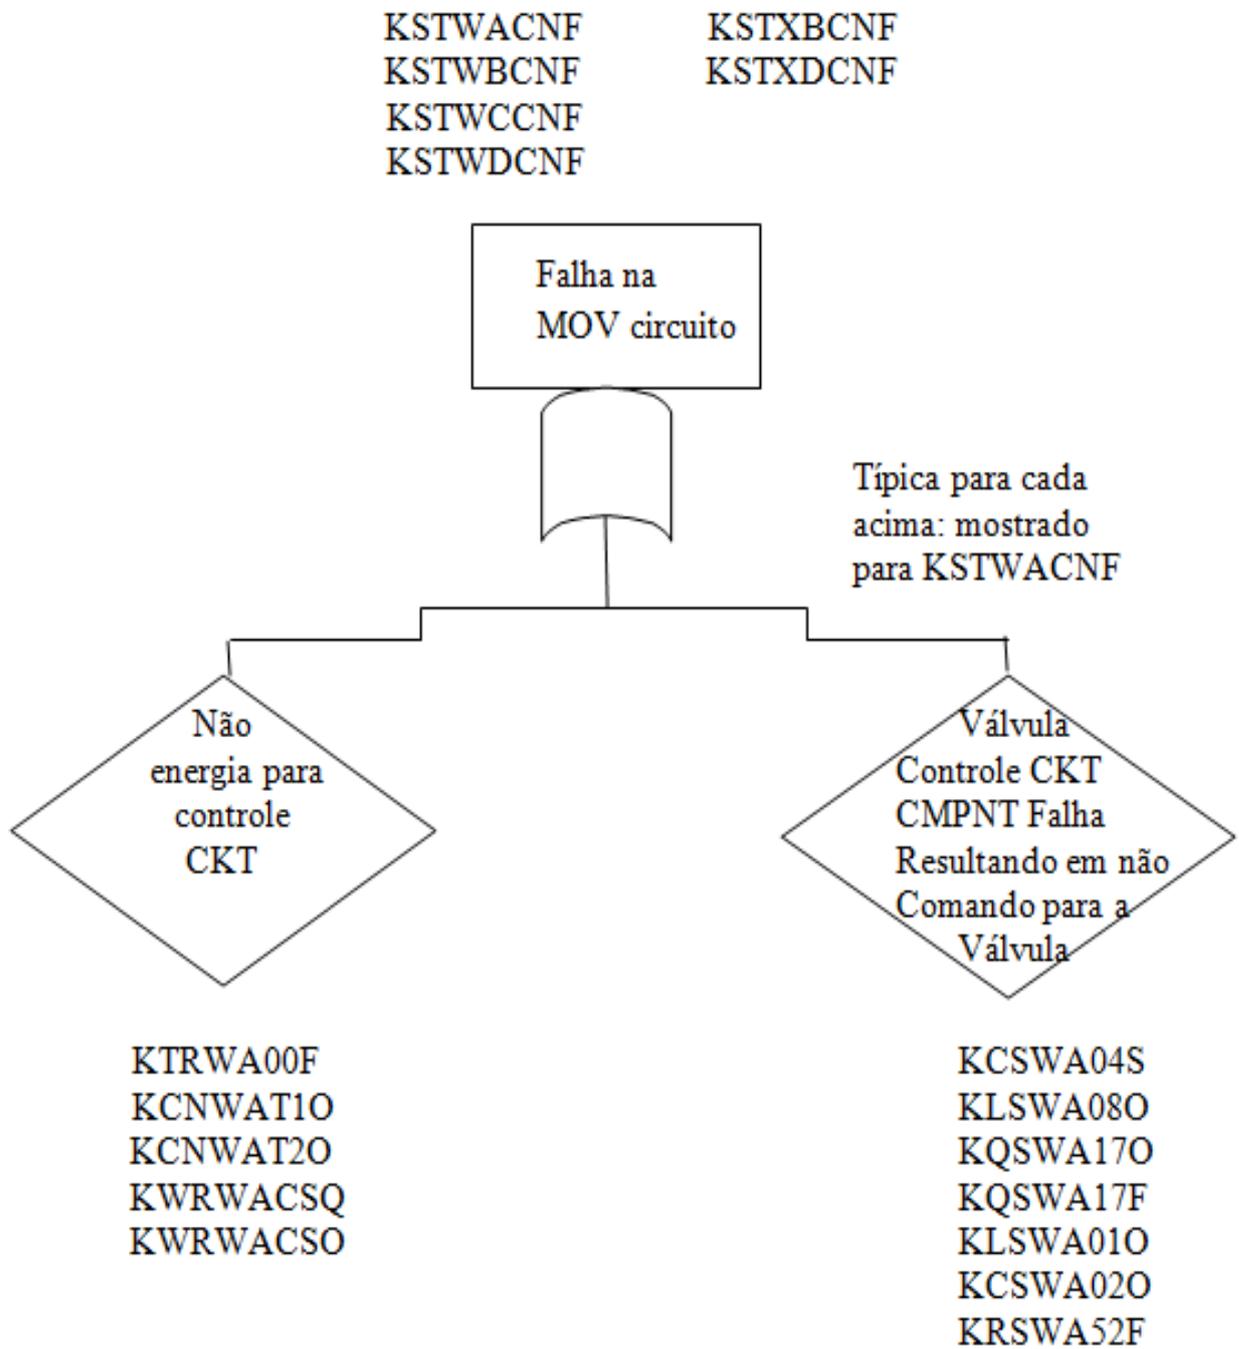


B.3 SUBÁRVORE DE FALHAS PARA O CÁLCULO DO HX1A, HX1B, HX1C E HX1D



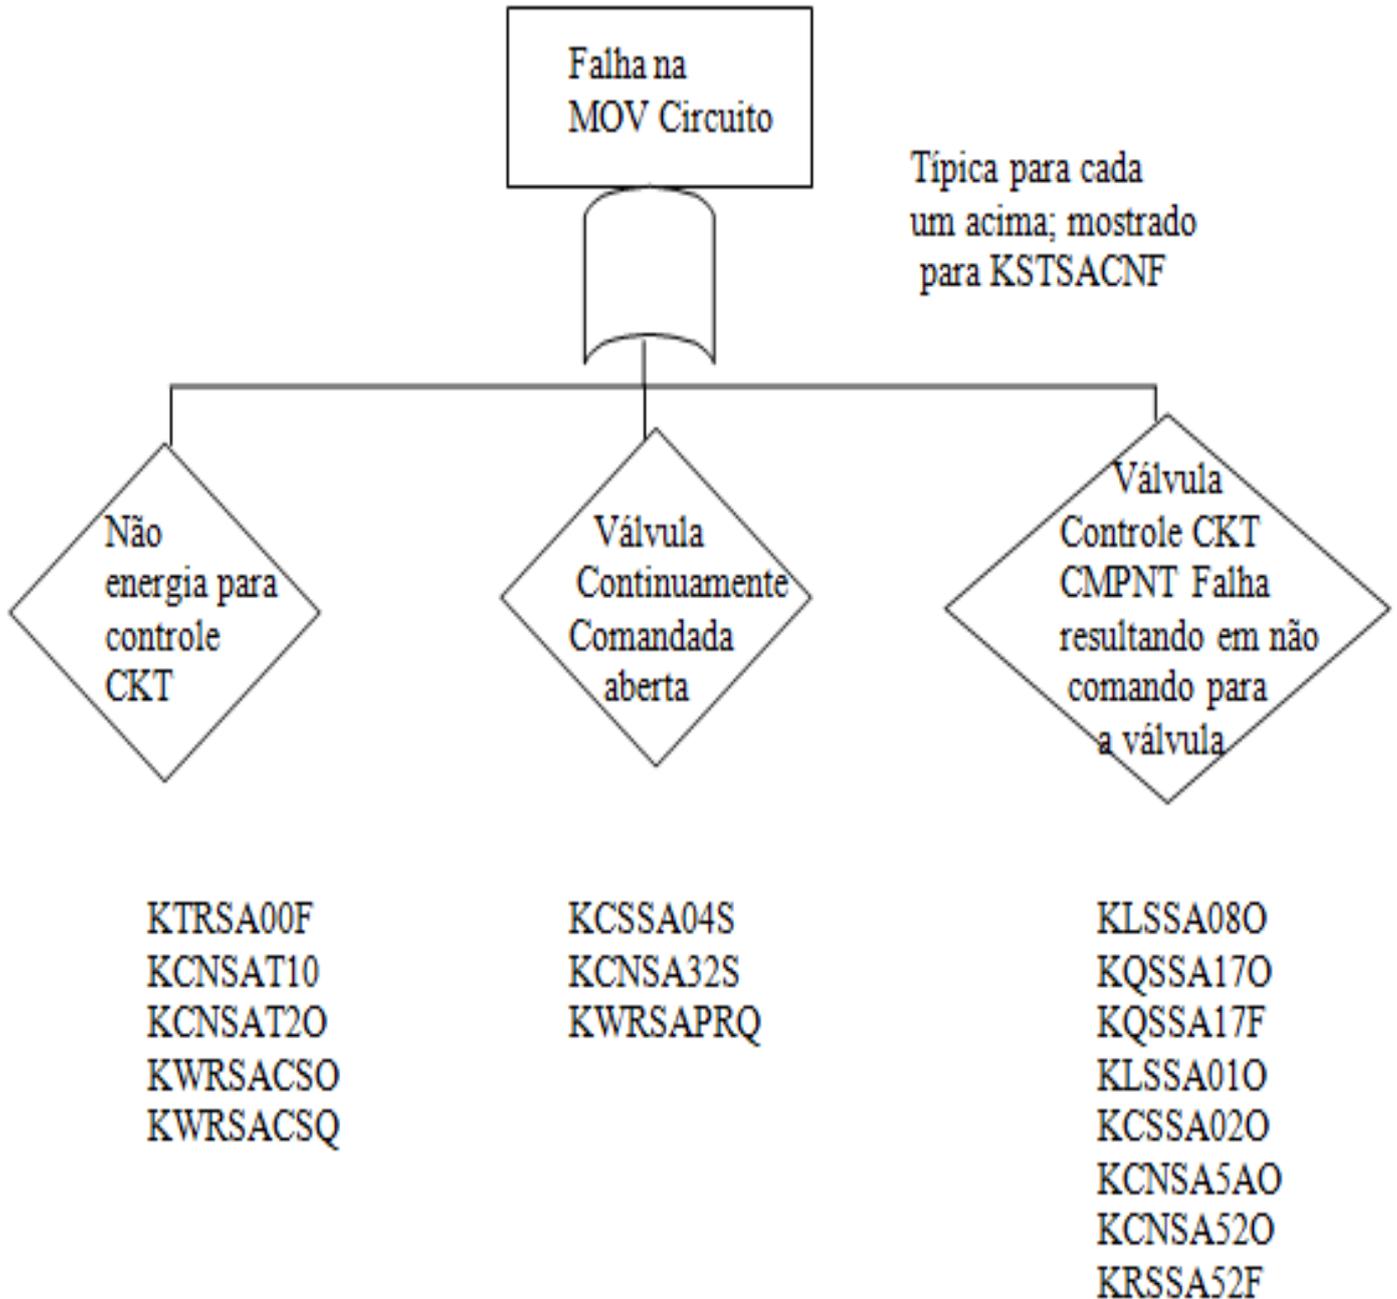
(HX1A)	(HX1B)	(HX1A)	(HX1B)	(HX1A)	(HX1B)
KXV1A20X	KXV1B20X	KCS4A43X	KCS4B43X	KCS5A43X	KCS5B3C
KCV1A20C	KCV1B20C	KCS04A3C	KCS04B3C	KCS05A3C	KCS05B3C
KXV1A21X	KXV1B21X	KCN04A4C	KCN04B4C	KCN05A4C	KCN05B4C
KCV1A21C	KCV1B21C	(HX1C)	(HX1D)	(HX1C)	(HX1D)
(HX1C)	(HX1D)	KCS4C43X	KCS4D43X	KCS5C43X	KCS5D43X
KXV1C20X	KXV1D20X	KCS04C3C	KCS04D3C	KCS05C3C	KCS5DC3C
KCV1C20C	KCV1D20C	KCN04C4C	KCN04D4C	KCN05C4C	KCN05D4C
KXV1C21X	KXV1D21X				
KCV1C21C	KCV1D21C				

B.4SUBÁRVORES (FALHA5 E FALHA7)

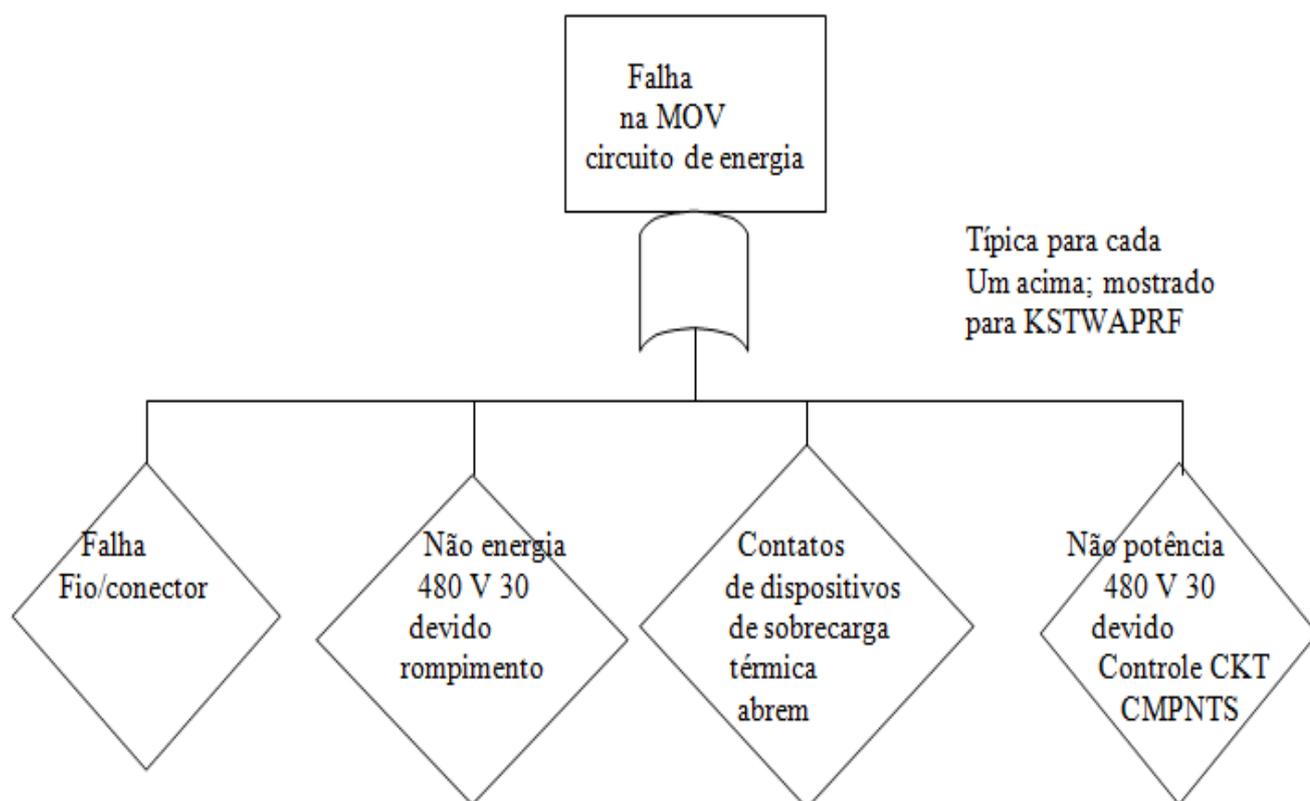


KSTSACNF
KSTSBCNF
KSTSCCNF
KSTSDCNF

KSTTACNF
KSTTCCNF



KSTXBPRF KSTSAPRF
 KSTXDPRF KSTSBPRF
 KSTTAPRF KSTSCPRF
 KSTTCPRF KSTSCPRF
 KSTWAPRF
 KSTWBPRF
 KSTWCPRF
 KSTWDPRF



KWRWAVPQ
 KWRWAVPO

KCBWAVPY
 KCBWAPAO
 KCBWAPBO
 KCBWAPCO
 KCBWAVPF

KCNWAPO
 KCNWABPO
 KCNWACPO

KCNWAPAO
 KCNWAPBO
 KCNWAPCO
 KCNWAPAC
 KCWNAPCC

APÊNDICE C – TABELAS

C.1 PROBABILIDADE DE EVENTOS UTILIZADOS NA AVALIAÇÃO DA ÁRVORE DE FALHAS DO CHRS

PROBABILIDADES DE EVENTOS UTILIZADOS NA AVALIAÇÃO DE ÁRVORES DE FALHAS DO CHRS				
Evento	Taxa de Falha (Hr ⁻¹)	Tempo de exposição de falha (Hr)	Indisponibilidade q	EF ^(a)
KCV1A20C			1×10^{-4}	3
KCV1A21C			1×10^{-4}	3
KCS04A3C			ε	Desprezível
KCN04A4C			ε	Desprezível
KCS05B3C			ε	Desprezível
KCN05A4C			ε	Desprezível
KXV1A20X			3×10^{-5}	3
KXV1A21X			3×10^{-5}	3
KCS4A43X			1×10^{-3}	3
KCS4B43X			1×10^{-3}	3
KHEVENTY			1×10^{-5}	3
K001000N			1.0×10^{-3}	3
KTLUNISF			ε	Desprezível
KPPLVLSP			ε	Desprezível
KST2H11F			3.7×10^{-2}	3
KMVXBOOK			1×10^{-3}	3
KMVXDOOK			1×10^{-3}	3
KMVTAAOK			1×10^{-3}	3
KMVTCOOK			1×10^{-4}	3
KSTXBPRF			1.3×10^{-4}	10
KSTXDPRF			1.3×10^{-4}	10
KSTTAPRF			1.3×10^{-4}	10
KSTTCPRF			1.3×10^{-4}	10
KSTXBCNF			3.5×10^{-4}	10
KSTXDCNF			3.5×10^{-4}	10
KSTTACNF			3.5×10^{-4}	10
KSTTCCNF			3.5×10^{-4}	10
JJOO			1.1×10^{-4}	3
JKOO			1.1×10^{-4}	3
JCOO			4.2×10^{-4}	3
JDOO			4.2×10^{-4}	3

C.2 PROBABILIDADE DE EVENTOS UTILIZADOS NA AVALIAÇÃO DA SUBÁRVORE KSTXBPRF

PROBABILIDADES DOS EVENTOS UTILIZADOS NA AVALIAÇÃO DE SUBÁRVORES KSTXBPRF ^(a)				
Evento	Taxa de Falha (Hr ⁻¹)	Tempo de exposição de falha (Hr)	Indisponibilidade q	EF
KCBWAVPF	1.0×10^{-6}	28	2.8×10^{-5}	3
KWRWAVPQ	3.0×10^{-7}	28	8.4×10^{-6}	10
KWRWAVPO	3.0×10^{-6}	28	8.4×10^{-5}	3
KCBWAVPY	ϵ		ϵ	Desprezível
KCBWAPAO	1.0×10^{-8}	28	2.8×10^{-5}	3
KCBWAPBO	1.0×10^{-8}	28	2.8×10^{-5}	3
KCBWAPCO	1.0×10^{-8}	28	2.8×10^{-5}	3
KCNWAAPO	3.0×10^{-8}	28	8.4×10^{-7}	10
KCNWABPO	3.0×10^{-8}	28	8.4×10^{-7}	10
KCNWACPO	3.0×10^{-8}	28	8.4×10^{-7}	10
KCNWAPAO	3.0×10^{-8}	28	8.4×10^{-7}	10
KCNWAPBO	3.0×10^{-8}	28	8.4×10^{-7}	10
KCNWAPCO	3.0×10^{-8}	28	8.4×10^{-7}	10
KCNWAPAC	1×10^{-8}	28	2.8×10^{-7}	10
KCNWAPCC	1×10^{-8}	28	2.8×10^{-7}	10

(a) Esta lista de probabilidades de eventos é idêntica à dos FSTXDPRF, KSTTAPRF, e KSTTCPRF.

PROBABILIDADES DOS EVENTOS UTILIZADOS NA AVALIAÇÃO DE SUBÁRVORES KSTXBCNF ^(a)				
Evento	Taxa de Falha (Hr ⁻¹)	Tempo de exposição de falha (Hr)	Indisponibilidade q	EF
KREWA52F			1.0×10^{-4}	3
KTRWA00F (2)	2.0×10^{-6}	28	5.6×10^{-5}	3
KCNWAT10	1.0×10^{-7}	28	2.8×10^{-6}	3
KCNWAT20	1.0×10^{-7}	28	2.8×10^{-6}	3
KWRWACSQ	3.0×10^{-7}	28	8.4×10^{-6}	10
KWRWACSO	3.0×10^{-6}	28	8.4×10^{-5}	3
KCSWA04S	1.0×10^{-8}	28	2.8×10^{-7}	10
KLSWA080	3.0×10^{-8}	28	8.4×10^{-7}	3
KQSWA170	3.0×10^{-8}	28	8.4×10^{-7}	3
KQSWA17F			1.0×10^{-4}	3
KLSWA010	3.0×10^{-8}	28	8.4×10^{-7}	3
KCSWA020	3.0×10^{-8}	28	8.4×10^{-7}	10

(a) Esta lista de probabilidades de eventos é idêntica à dos KSTXDCNF, KSTTACNF, e KSTTCCNF.

C.3 CÓDIGO DE IDENTIFICAÇÃO DO SISTEMA PWR

CÓDIGO DE IDENTIFICAÇÃO DO SISTEMA PWR	
<u>Código</u>	<u>Nome do sistema</u>
A	Acumulador (ACC)
G	Vazamento da Contenção (CL)
N	Sistema de Controle de Limitação de Consequência (CLCS)
K	Sistema de Remoção de Calor da Contenção (CHRS)
C	Sistema de Injeção da pulverização da Contenção (CSIS)
D	Sistema de Recirculação do Spray da Contenção (CSRS)
J	Energia Elétrica (EPS)
F	Sistema de Injeção de Alta Pressão (HPCIS)
H	Sistema de Recirculação de Alta Pressão (HPCRS)
B	Sistema de Injeção de Baixa Pressão (LPIS)
E	Sistema de Recirculação de Baixa Pressão (LPRS)
L	Sistema de Adição de Hidróxido de Sódio (SHAS)
I	Sistema de Proteção do Reator (RPS)
M	Sistema de Controle da Injeção de Segurança (SICS)
P	Água de Alimentação Auxiliar (AF)

C.4 CÓDIGO DE COMPONENTE

CÓDIGO DE COMPONENTE			
<u>Componentes Mecânicos</u>			
Acumulador	AC	Comporta	SL
Ventilador	BL	Reservatório	SP
Unidade de Controle de Acionamento da Vareta	CD	Subárvore	ST
Placa de Cobertura	FA	Tanque	TK
Amortecedor	DM	Tubulação	TG
Diesel	DL	Turbina	TB
Junta de Expansão	XJ	Válvula de Retenção	CV
Filtro ou Coador	FL	Válvula de Operação Explosiva	EV
Garrafa de Gás	GB	Válvula de Operação Hidráulica	HV
Vedação	GK	Válvula Manual	XV
Trocador de Calor	HE	Válvula de Operada por Motor	MV
Bico	NZ	Válvula de Operação Pneumática	AV
Orifício	OR	Válvula de Alívio	RV
Tubo	PP	Válvula de Segurança	SV
Tubo de Tampa	CP	Válvula de Operada por Solenoide	KV
Vaso de Pressão	PV	Válvula de Interromper Verificação	DV
Bomba	PM	Válvula de Alívio no Vácuo	VV
Barra de Controle do Reator	ED	Vent	VT
Unidade de Refrigeração	RF	Fonte	WL

Componentes Elétricos

Amplificador	AM	Interruptor Terra	GS
Anunciador	BN	Relé	RE
Bateria	BY	Relé ou Contato do Interruptor	CN
Carregador de Bateria	BC	Botão de Reinício	RS
Barramento	BS	Resistor, Dispositivo de Temp.	RT
Cabo	CA	Comparador de Sinal	AD
Disjuntor	CB	Interruptor de Pressão	OS
Embreagem	CL	Interruptor de Torque	QS
Interruptor de Controle	CS	Interruptor de Temperatura	TS
Bobina	CO	Junta do Terminal	TM
Detector	DI	Diodo ou Retificador	DE
Fonte de Alimentação DC	DC	Fusível	FU
Chave de Vazão	FS	Gerador	GE
Resistência de Aquecimento	HG	Heat Tracing	HT
Módulo de Entrada	IM	Botão de Teste	SB
Inversor (estado sólido)	IV	Sobrecarga Térmica	OL
Interruptor de Nível	ES	Cronômetro	TI
Luz	LT	Transformador de Corrente	CT
Interruptor Limite	LS	Transformador de Potência	OT
Interruptor Manual	SW	Transformador de Energia	TR
Motor	MO	Transmissor de Fluxo	TF
Motor de Arranque	MS	Transmissor de Nível	TL
Detector de Nêutrons	ND	Transmissor de Pressão	TP
Potenciômetro	PT	Transmissor de Temperatura	TT
Gravador	RC	Fio	WR
Pára-raios	LA	Evento (onde não há componente envolvido)	OO

C.5 CÓDIGO DE MODO DE FALHA

CÓDIGO DE MODOS DE FALHA	
<u>Modos de Falha</u>	
Fechado	C
Desengatado	G
Não fecha	K
Não abre	D
Não inicia	A
Engatado	E
Excede o limite	M
Vazamento	L
Perda da função	F
Falta de manutenção	Y
Nenhuma entrada	N
Abrir	O
Circuito aberto	B
Falha operacional	X
Sobrecarga	H
Conectado	P
Ruptura	R
Curto circuito	Q
Curto para terra	S
Falha de transferência	T

C.6 DIFERENTES EVENTOS DA ÁRVORE DE FALHAS DO CHRS

	Componente	Símbolo	Probabilidade
1	3 de 4 trocadores de calor não removem calor suficiente do fluido do spray	G_01	Portão OU
2	3 de 4 trocadores de calor falham o sistema quando ocorre falha da energia	G_02	Portão OU
3	Falha da energia 1H e 1A e trocador de calor 1B e 1D	G_03	Portão E
4	Falha na energia Bus CSRS	G_04	Portão OU
5	Insuficiente voltagem (125 V DC) do Bus 1A para o circuito de controle	JK00	0.00011
6	Insuficiente voltagem (480 V AC) do Bus 1H para a bomba	JD00	0.00042
7	Falha do trocador 1B ou 1D	G_05	Portão OU
8	Falha no trocador de calor 1B	HX1B	0.0023
9	Falha no trocador de calor 1D	HX1D	0.0023
10	Falha da energia 1J e 1B e trocador de calor 1A e 1C	G_06	Portão E
11	Falha na energia Bus CSRS	G_07	Portão OU
12	Insuficiente voltagem (125 V DC) do Bus 1B para o circuito de controle	JJ00	0.00011
13	Insuficiente voltagem (480 V AC) do Bus 1J para a bomba	JC00	0.00042
14	Falha do trocador 1A ou 1C	G_08	Portão OU
15	Falha no trocador de calor 1A	HX1A	0.0023
16	Falha no trocador de calor 1C	HX1C	0.0023
17	Erro do operador- Toda saída de ar a esquerda do trocador de calor é fechada	Falha_01	0.00001
18	Sistema falha com 3 de 4 trocadores de calor (excluindo falha na energia elétrica)	G_09	Portão OU
19	Falha no trocador 1A, 1B e 1C	G_10	Portão E
20	Falha no trocador 1A	G_11	Portão OU
21	Falha no trocador 1A	HX1A	0.0023
22	Bomba CSRS 1 RS-P. Perna fria 1A	E	0.00053
23	Falha no trocador 1B	G_12	Portão OU
24	Falha no trocador 1B	HX1B	0.0023
25	Bomba CSRS 1 RS-P. Perna fria 1B	F	0.00053
26	Falha no trocador 1C	G_13	Portão OU
27	Falha no trocador 1C	HX1C	0.0023
28	Bomba CSRS 1 RS-P. Perna fria 2A	C	0.00053
29	Falha no trocador 1A, 1B e 1D	G_10	Portão E
30	Falha no trocador 1A	HX0A	0.00283
31	Falha no trocador 1B	HX0B	0.00283
32	Falha no trocador 1D	G_15	Portão OU

33	Falha no trocador 1D	HX1D	0.0023
34	Bomba CSRS 1 RS-P. Perna fria 2B	D	0.00053
35	Falha no trocador 1A, 1B e 1D	G_16	Portão E
36	Falha no trocador 1B	HX0B	0.00283
37	Falha no trocador 1C	HX0C	0.00283
38	Falha no trocador 1D	HX0D	0.00283
39	Água insuficiente no canal de entrada	G_17	Portão E
40	Perda da energia externa	Falha_02	0.001
41	Falha sozinha e dupla que permite a entrada do canal para drenar	G_18	Portão OU
42	Falha no sensor do nível do canal	Falha_03	<i>Epsilon</i>
43	Falha no MOV-CW-200B para fechar	G_19	Portão OU
44	Insuficiente 480 V 30 PWR sobre Bus 2H1-1. Depois da perda da energia externa	Falha_04	0.037
45	Falha no MOV energia CKT (São Subárvores)	Falha_05	0.00052
46	Falha na válvula para fechar	Falha_06	0.004
47	Falha no MOV CONT CKT (São Subárvores)	Falha_07	0.0014

APÊNDICE D – RESULTADOS

D.1 RESULTADOS DA REDE BAYESIANA CALCULADA NO NETICA, SEM UTILIZAR A PROPAGAÇÃO DE INCERTEZAS

Falha_01	
Falha	1e-005
Funciona	0.99999
Falha_02	
Falha	0.001
Funciona	0.999
Falha_03	
Falha	0
Funciona	1
Falha_04	
Falha	0.037
Funciona	0.963
Falha_05	
Falha	0.00052
Funciona	0.99948
Falha_06	
Falha	0.004
Funciona	0.996
Falha_07	
Falha	0.0014
Funciona	0.9986
G_01	
Falha	5.7562e-005
Funciona	0.99994
G_02	
Falha	4.87e-006
Funciona	1
G_03	
Falha	2.435e-006
Funciona	1
G_04	
Falha	0.00052995
Funciona	0.99947
G_05	
Falha	0.0045947
Funciona	0.99541
G_06	
Falha	2.435e-006
Funciona	1
G_07	
Falha	0.00052995
Funciona	0.99947
G_08	
Falha	0.0045947
Funciona	0.99541

G_17	
Falha	4.2693e-005
Funciona	0.99996
G_18	
Falha	0.042693
Funciona	0.95731
G_19	
Falha	0.0059116
Funciona	0.99409
HX1A	
Falha	0.0023
Funciona	0.9977
HX1B	
Falha	0.0023
Funciona	0.9977
HX1C	
Falha	0.0023
Funciona	0.9977
HX1D	
Falha	0.0023
Funciona	0.9977
JC00	
Falha	0.00042
Funciona	0.99958
JD00	
Falha	0.00042
Funciona	0.99958
JJ00	
Falha	0.00011
Funciona	0.99989
JK00	
Falha	0.00011
Funciona	0.99989